



UNIVERSIDADE FEDERAL DO MARANHÃO - UFMA
CENTRO DE CIÊNCIAS DE CHAPADINHA - CCCh
CURSO DE ENGENHARIA AGRÍCOLA



**IMAGENS DE SATÉLITES E UAV NO MONITORAMENTO DE UMA LAVOURA
DE SOJA.**

JANINE QUADROS CASTRO

CHAPADINHA - MA

JULHO DE 2023

JANINE QUADROS CASTRO

**IMAGENS DE SATÉLITES E UAV NO MONITORAMENTO DE UMA LAVOURA
DE SOJA**

Trabalho de Conclusão de Curso apresentado à banca examinadora na Universidade Federal do Maranhão, Centro de Ciências de Chapadinha, como requisito para a obtenção do título de Bacharel em Engenharia Agrícola.

Orientador: Prof. Dr. Washington da Silva Sousa.
Coorientador: Prof. Dr. Marcus Willame Lopes Carvalho.

CHAPADINHA - MA

JULHO DE 2023

Ficha gerada por meio por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).

Núcleo Integrado de Bibliotecas/UFMA

Castro, Janine Quadros.

IMAGENS DE SATÉLITES E UAV NO MONITORAMENTO DE UMA
LAVOURA DE SOJA / Janine Quadros Castro. - 2023.

52 p.

Coorientador(a): Marcus Willame Lopes Carvalho.

Orientador(a): Washington da Silva Sousa.

Monografia (Graduação) - Curso de Engenharia Agrícola,
Universidade Federal do Maranhão, Chapadinha - MA, 2023.

1. Agricultura Digital. 2. Drone. 3. Sensoriamento Remoto. I. Carvalho, Marcus Willame Lopes. II. Sousa, Washington da Silva. III. Título.

JANINE QUADROS CASTRO

**IMAGENS DE SATÉLITES E UAV NO MONITORAMENTO DE UMA LAVOURA
DE SOJA**

Trabalho de Conclusão de Curso apresentado à banca examinadora na Universidade Federal do Maranhão, Centro de Ciências de Chapadinha, como requisito para a obtenção do título de Bacharel em Engenharia Agrícola.

Aprovado em: 21 / 07 /2023

Comissão examinadora

Prof. Dr. Washington da Silva Sousa
Universidade Federal do Maranhão

Prof. Dr. Patrício Gomes Leite
Universidade Federal do Maranhão

Me. Eduardo Arouche da Silva
Mestre em Engenharia de Sistemas Agrícolas da Escola
Superior de Agricultura, (ESALQ/USP)

Á Deus, por ter me dado forças diante de tantas tempestades. Ao meu pai, Francisco Xavier Freitas Carvalho (*in memoriam*) por ter me repassado ensinamentos pautados na ética e no respeito ao próximo. A minha mãe, Maria Sousa Carvalho, a principal incentivadora dos meus sonhos e projetos de vida.

DEDICO

AGRADECIMENTOS

Agradeço a Deus por ter me dado forças para seguir adiante com meus sonhos e projetos, mesmo frente a tantas intempéries.

Ao meu pai, Francisco Xavier Carvalho (*in memoriam*), por todos os cuidados e por sempre buscar me repassar ensinamentos pautados na ética e no respeito ao próximo. A minha mãe, Maria Sousa Carvalho, que sempre apoiou as minhas decisões e orou incessantemente para que tudo ocorresse bem comigo. A Aldeniza Carvalho, minha principal incentivadora e irmã de coração. Ao meu irmão Wadson Carvalho e a minha madrinha/irmã, Zulima Carvalho por todo o apoio que prestaram a mim.

Agradeço imensamente à Odaiza das Graças Carvalho, seu marido José de Almeida Rocha e ao meu padrinho, Luis Pereira Carvalho, por terem sido peças-chave em minha jornada até a conclusão do curso. O apoio de vocês foi fundamental para o sucesso desta etapa tão importante em minha vida acadêmica. Expresso minha profunda gratidão por todo o apoio contínuo e encorajamento que vocês me proporcionaram ao longo dessa trajetória.

Ao meu companheiro, Luiz Alberto por tornar esta trajetória menos árdua. Sua presença ao meu lado trouxe conforto, apoio e motivação durante o percurso.

Ao meu orientador Washington da Silva Sousa, pela orientação, confiança, apoio e paciência durante esse tempo, muito obrigada.

A professora Raissa Salustriano Matos, por todo o apoio. Aos meus amigos Max Wiilian e Fabíola, pelos momentos incríveis que compartilhamos juntos durante a graduação.

A Eduardo Arouche, uma pessoa que possui minha admiração e respeito, o qual tenho uma gratidão imensa por contribuir de forma significativa com a minha entrada na iniciação científica.

Ao GETAD por proporcionar valiosa experiência de aprendizado teórico-prático.

A turma 2017.1 do curso de Engenharia Agrícola, com quem partilhei 5 anos, e apesar dos altos e baixos sempre se apoiou e compartilhou de momentos inesquecíveis. Vocês deixaram os dias da minha graduação mais leves: Aurélio, Arlindo, Atacilia, Caio, Diemerson, Elves, Enzo Laércio, Geovane, Ivanária, João Matheus, João Pedro, Larissa, Letícia, Marcos, Tamara, Vinicius e Wesley.

A todos que contribuíram direta e indiretamente com este trabalho.

O saber a gente aprende com os mestres e os livros.
A sabedoria, se aprende é com a vida e com os
humildes.

(Cora Coralina)

RESUMO

O sensoriamento remoto por meio de imagens de satélites e de sensores embarcados em Unmanned Aerial Vehicles (UAVs), desempenha um papel fundamental no cenário onde as tecnologias de Agricultura Digital têm a capacidade de oferecer soluções economicamente viáveis e, ao mesmo tempo, permitem um monitoramento mais detalhado das lavouras agrícolas. Assim, objetivou-se analisar características e desempenhos de índices de Vegetação obtidos a partir de imagens de satélites e UAV, processadas através das ferramentas Google Earth Engine (GEE) e Q-GIS. A área de estudo corresponde a 2,53 hectares, onde a soja encontrava-se a 114 dias de pós-semeadura, no estágio vegetativo R8. Desse modo, utilizou-se o método da comparação entre as diferentes fontes de dados através da análise de diagramas de caixas (boxplot) e histogramas de frequências dos pixels presentes nas imagens. O voo foi realizado com auxílio de um Unmanned Aerial Vehicle (UAV) modelo DJI Phantom 4 Pro a uma altitude de 62,6 metros. O drone possui uma câmera FC6310 de 20 megapixels, por meio da qual foi possível capturar 70 imagens, e para as imagens de satélites foram utilizados dados dos sensores das plataformas Planet Scope, Landsat 8 e Sentinel-2. Foi verificado que os dados do índice NDVI obtidos das imagens de UAV mostraram uma maior variabilidade nos valores. O índice NDRE do Planet Scope e Sentinel-2 demonstrou sinais de saturação devido a presença de outliers. Já o índice VARI para as diferentes fontes de dados revelou uma faixa mais ampla de valores e valores extremos abaixo do intervalo normal. Com isso, o NDVI do satélite Planet Scope, para este estudo, apresentou maior amplitude e consistência de valores. Destaca-se a importância de se considerar as particularidades de cada fonte de dados no monitoramento e controle de áreas plantadas.

Palavras-chaves: Agricultura Digital; Drone; Sensoriamento Remoto.

ABSTRACT

Remote sensing through satellite images and sensors embedded in Unmanned Aerial Vehicles (UAVs) plays a fundamental role in the scenario where Digital Agriculture technologies have the capability to offer economically viable solutions while enabling more detailed monitoring of agricultural fields. Thus, the objective was to analyze the characteristics and performance of Vegetation Indices obtained from satellite and UAV images, processed through Google Earth Engine (GEE) and Q-GIS tools. The study area corresponds to 2.53 hectares, where soybean was at 114 days after planting, in the vegetative stage R8. Hence, the comparison method was used to analyze the different data sources through boxplot and frequency histogram analysis of the pixels present in the images. The flight was conducted with the assistance of a DJI Phantom 4 Pro Unmanned Aerial Vehicle (UAV) at an altitude of 62.6 meters. The drone has a 20-megapixel FC6310 camera, which enabled the capture of 70 images, while satellite images were obtained from the sensors of Planet Scope, Landsat 8, and Sentinel-2 platforms. It was observed that the NDVI data obtained from UAV images showed greater variability in values. The NDRE index from Planet Scope and Sentinel-2 demonstrated signs of saturation due to the presence of outliers. On the other hand, the VARI index for the different data sources revealed a wider range of values and extreme values below the normal interval. Consequently, the NDVI from the Planet Scope satellite, for this study, showed greater amplitude and consistency of values. It is essential to consider the particularities of each data source in the monitoring and control of cultivated areas.

Keywords: Digital Agriculture; Remote Sensing; Drone.

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	15
2.1	Objetivo geral	15
2.2	Objetivos específicos	15
3	REFERENCIAL TEÓRICO	16
3.1	A Cultura da Soja	16
3.2	Agricultura Digital	17
3.3	Sensoriamento Remoto na Agricultura	18
3.4	Satélites	21
3.4.1	Landsat-8	21
3.4.2	Sentinel-2.....	21
3.4.3	Planet Scope	22
3.4.4	Veículos Aéreos não Tripulados.....	23
3.5	Ferramentas de Processamento Digital de Imagens	24
3.6	Comportamento Espectral da Vegetação	25
3.7	Índices de Vegetação	25
3.7.1	NDVI	26
3.7.2	NDRE	27
3.7.3	GLI	27
3.7.4	VARI	28
4	MATERIAL E MÉTODOS	29
4.1	Caracterização da Área de Estudo	29
4.2	Aquisição e Processamento dos Dados de Sensores Orbitais	30
4.3	Aquisição e Processamento dos Dados de Sensores Aerotransportados	31
5	RESULTADOS E DISCUSSÕES	36
6	CONCLUSÕES	45
	REFERÊNCIAS	46

ÍNDICE DE TABELAS

Tabela 01: Informações do satélite Landsat-8.....	21
Tabela 02: Informação espectral e resolução espacial do Sentinel-2.....	22
Tabela 03: Informações do Planet Scope.....	23

ÍNDICE DE ILUSTRAÇÕES

Figura 01: Fases da evolução da agricultura. Fonte: Adaptado de Embrapa (2020).....	17
Figura 02: Etapas do processo de obtenção e distribuição das imagens de SR. Fonte: Adaptado Zanotta (2019).....	19
Figura 03: Ondas eletromagnéticas e espectro eletromagnético. Fonte: Adaptado de Giovanini (2022)	20
Figura 04: Quad copter. Fonte: (VELUSAMY et al., 2021).....	24
Figura 05: Reflectância de uma folha sadia. Fonte: Adaptado de (SILVA, 2020).	25
Figura 06: Escala de valores e as cores correspondentes ao NDVI. Fonte: (ANABITARTE et al., 2020).....	26
Figura 07: Mapa de localização da área de estudo, Buriti, MA, Brasil.	29
Figura 08: Etapas metodológicas empregadas na obtenção e tratamento dos dados. Fonte: Autor.....	30
Figura 09: Fluxograma de aquisição e processamento dos dados do sensor aerotransportado. Fonte: Autor.....	32
Figura 10: Phantom 4 Pro Fonte: Google Imagens	33
Figura 11: Manuseio e calibração do Phantom 4 Pro.....	33
Figura 12: Plano de voo.	34
Figura 13: Ortomosaico da área de estudo.	35
Figura 14: Boxplot dos valores NDVI das imagens do UAV, Sentinel (2), Landsat (8) e Planet Scope.	36
Figura 15: Boxplot dos valores NDRE das imagens do UAV, Sentinel-2, Landsat 8 e Planet Scope.	37
Figura 16: Boxplot dos valores VARI das imagens do UAV, Sentinel-2, Landsat 8 e Planet Scope.	38
Figura 17: Imagens de NDVI dos dados orbitais aerotransportado.	39
Figura 18: Imagens de NDRE dos dados orbitais aerotransportado.	40
Figura 19: Imagens de VARI dos dados orbitais e aerotransportado.....	41

Figura 20: Histogramas GLI do UAV, NDVI do Planet Scope, Sentinel-2 e Landsat-8.....	42
Figura 21: Histogramas NDRE do Planet Scope e Sentinel-2.	43
Figura 22: Histogramas de distribuição e frequência dos pixels referentes aos mapas de distribuição dos IVs.	43

1 INTRODUÇÃO

A soja (*Glycine max* (L.) Merrill) é uma das culturas que mais tem impacto sob a economia do Brasil, colocando o país no ranking de maior produtor mundial do grão, assim para o ano comercial 2022/2023 há previsão de um recorde de produção equivalente a 154,6 milhões de toneladas, um aumento de 23,1% em relação ao ano anterior, maior rendimento já registrado, o que coloca o país frente à grandes desafios tecnológicos que implicam aumento de produtividade associada a produção sustentável que atendam a crescente demanda da população (CONAB, 2023).

O Norte e Nordeste do Brasil são a grande fronteira agrícola denominada Matopiba, abrangendo Cerrado dos estados do Maranhão, Tocantins, Piauí e Bahia. Estimativas apontam que a região é responsável por 10% da produção nacional de grãos, especialmente soja Fundaj (2021). Há previsão que a produção de soja no Matopiba dobre em 15 anos (APROSOJA, 2022a). Assim, o estado do Maranhão destaca-se, principalmente na microrregião de Chapadinha e do Baixo Parnaíba desde os anos 2000, na produção de soja SANTOS et al (2019).

Nesse sentido, Chamara (2022) destaca a importância do emprego das tecnologias nas lavouras agrícolas e dá ênfase ao sensoriamento remoto através de imagens de satélites e de sensores embarcados em Veículos Aéreos não Tripulados (VANTs) em inglês UAV-Unmanned Aerial Vehicle, haja vista que são capazes de estabelecer soluções mais viáveis economicamente além de permitir o monitoramento mais detalhado das culturas agrícolas (KAKAMOUKAS et al., 2022).

Assim, os mapas digitais provenientes do processamento de imagens de UAVs e Satélites possibilitam a visualização remota de grandes áreas, sem contado direto, permitindo a detecção de problemas. Fatores como índice de área foliar, atividade fotossintética, vigor das plantas, entre outros, podem ser observados com mais precisão (MOLIN et al., 2021).

Nesse sentido, Zhao et al. (2021) menciona que existem ferramentas como a plataforma Google Earth Engine (GEE) e o software Q-gis que auxiliam no processamento de imagens e elaboração de mapas a partir de cálculos de Índices de Vegetação das culturas agrícolas. Os IVs são obtidos por meio de equações matemáticas executadas com dados das imagens provenientes da reflectância das plantas à radiação eletromagnética (SOUZA; PARANHOS FILHO, 2021).

Ante ao exposto, este trabalho visa analisar características e desempenhos dos IVs obtidos a partir de imagens de satélites e UAV, que serão processadas por meio das ferramentas GEE e Q-GIS.

2 OBJETIVOS

2.1 Objetivo geral

Analisar as características e desempenhos dos índices de vegetação (NDVI, GLI, VARI e NDRE) obtidos a partir de diferentes fontes de dados (sensores orbitais e aerotransportados), por meio da comparação de suas variações, consistências e distribuições.

2.2 Objetivos específicos

- Análise dos índices de vegetação através da elaboração de mapas, boxplots e histogramas para cada fonte de dados (satélites e UAV);
- Comparação dos índices de vegetação entre as diferentes fontes de dados, identificando variações e consistências nos valores;
- Avaliação do desempenho e viabilidade das técnicas de sensoriamento remoto e agricultura digital no monitoramento e controle de áreas plantadas.

3 REFERENCIAL TEÓRICO

3.1 A Cultura da Soja

A soja é uma planta do tipo herbáceo e pertence a família Fabaceae, gênero *Glycine*, espécie *Glycine max* (L) Merrill. Trata-se de uma cultura anual de ciclo de vida que varia de 70 a 200 dias, dependendo da variedade, sua fenologia compreende os estágios vegetativos e reprodutivo. A sua produtividade está atrelada á fatores como época de plantio, espaçamento, fotoperíodo, disponibilidade de nutrientes, dentre outros (COSTA, 2020).

A primeira alusão a soja se deu pelo imperador chinês Shen-nung, conhecido como o “pai da agricultura”, que iniciou o cultivo da oleaginosa tendo por finalidade a alimentação humana o que desencadeou uma revolução alimentar naquele país. Em 1919, final da Primeira Guerra Mundial, o grão passou a ter grande importância para o mercado internacional e em 1921 com a fundação da American Soybean Association (ASA) a cadeia produtiva da soja se consolidou mundialmente, hoje, trata-se da proteína de origem vegetal com melhor custo benefício no que se refere a produção de carnes, ovos, leites e outros derivados (APROSOJA, 2022b).

No Brasil, a soja é a principal cultura em extensão de área e volume de produção, nesse sentido tem grande importância sob a economia do país que tem crescido de forma progressiva, isso dá em decorrência do aumento na demanda por alimentação humana e produção de ração animal, por conseguinte consolida-se como cadeia agroindustrial e também uma possibilidade para a produção de biocombustíveis (CONAB, 2017).

Assim, o avanço tecnológico no país tem contribuído significativamente para o desenvolvimento da cultura, uma vez que por meio de ferramentas tecnológicas e práticas sustentáveis, como o plantio direto, pode-se recuperar áreas degradadas tornando-as agricultáveis, desse modo, mesmo que haja aumento na demanda por produção de grãos nos próximos anos é possível produzir alimentos sem que haja pressão sob as áreas florestais e desta maneira contribuir com a preservação do meio ambiente (EMBRAPA, 2021).

A produção da soja no cerrado brasileiro tem crescido expressivamente nas últimas décadas, tendo seu desenvolvimento atrelado diretamente as técnicas de produção que vem sendo adotadas, principalmente, aquelas relacionadas com o manejo adequado de solo, mecanização e tecnologias digitais que auxiliam os produtores no monitoramento de suas lavouras (CASTILLO et al., 2021).

No estado do Maranhão, a expansão da fronteira agrícola tem se intensificado desde os anos 2000, inicialmente concentrada na região sul do estado. Ao longo do tempo, essa expansão

se disseminou para outras áreas, incluindo a microrregião de Chapadinha, que abrange os municípios de Chapadinha, Brejo, Buriti, Anapurus, Mata Roma e Milagres do Maranhão. Destaca-se que o município de Brejo é reconhecido como um dos principais produtores de soja na região, de acordo com Jardim (2021). Segundo dados do IBGE (2008), o município ocupa a segunda posição no ranking de produção de soja no estado.

3.2 Agricultura Digital

O setor agrícola nos últimos anos tem sido marcado por novas demandas que estão ligadas ao âmbito tecnológico onde ascende o movimento de transformação digital que foi responsável por fazer surgir a Agricultura 4.0 ou Agricultura Digital, por meio da qual é possível coletar grandes quantidades de dados das lavouras agrícolas em tempo real e tomar decisões assertivas. A figura a seguir mostra como se deu o processo de evolução da agricultura (MASSRUHÁ, 2020).

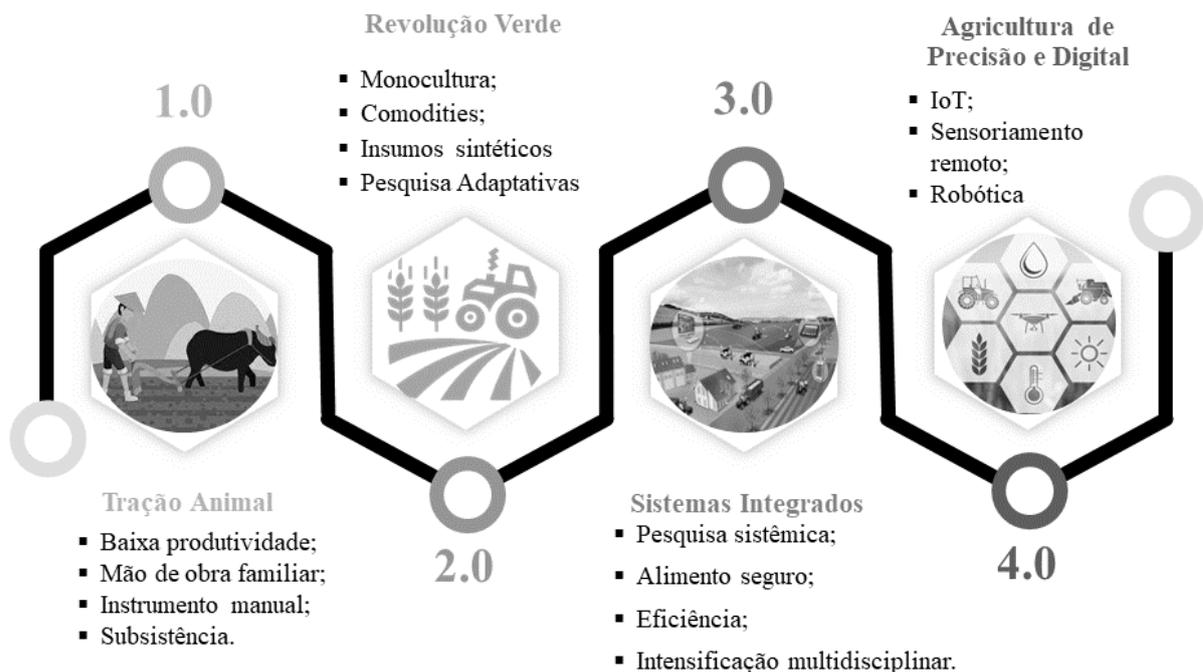


Figura 01: Fases da evolução da agricultura. **Fonte:** Adaptado de Embrapa (2020).

Nesse contexto, especialistas da produção agrícola dividem a evolução da agricultura em quatro momentos, conforme apontado pelo infográfico de linha de tempo, onde inicia-se com a agricultura tradicional ou 1.0 que operou durante milênios e sua principal característica era a instrumentalização manual e baixa produtividade. Esse cenário mudou a partir do século XX, quando as técnicas de mecanização somadas ao conhecimento técnico-científico começaram a ser introduzidos no meio rural, esse período ficou conhecido como início da

agricultura 2.0. Os avanços na agricultura continuaram ocorrendo e com eles a necessidade de produzir alimentos de forma segura, assim surgiram recursos mais desenvolvidos, como a pesquisa sistêmica, etc., dando início a agricultura 3.0. Hoje, o setor agrícola é marcado pela integração e conexão de tecnologias de precisão e digital, ficando conhecida como a era da Agricultura Digital (ZAPAROLLI, 2020).

A criação de um futuro sustentável na produção de alimentos requer grandes inovações, afirmou Searchinger (2014), pesquisador sênior do WRI. Avanços tecnológicos e científicos têm desempenhado um papel importante na ampla produção de alimentos, comprovado por estudos. O uso de tecnologias é fundamental para o sistema alimentar do futuro, fornecendo ferramentas cruciais para o gerenciamento agrícola, otimizando o planejamento e impulsionando a produtividade e a sustentabilidade dos negócios (SILVA; CAVICHIOLI, 2020).

Segundo a Associação Brasileira de Agricultura de Precisão e Digital, Asbraap (2022), os fatores relacionados a produtividade, qualidade, rentabilidade e sustentabilidade da produção agrícola, fazem parte de uma estratégia de gestão que está pautada no processamento e análise de dados temporais, individuais e espaciais, que somados a outros elementos tem por finalidade flexibilizar as tomadas de decisões, consoante com a variabilidade estimada, tornando-as mais eficientes e com menor impacto ao meio ambiente. Assim, a agricultura digital possibilita que as coletas de dados sejam através de sensores a bordo de máquinas agrícolas, Vants, satélites e outras plataformas (QUEIROZ et al., 2021).

3.3 Sensoriamento Remoto na Agricultura

O Sensoriamento Remoto (SR) é um método que permite obter informações da superfície terrestre por meio de imagens adquiridas do espaço, utilizando a radiação eletromagnética refletida ou emitida em diferentes regiões do espectro. Essa técnica é capaz de fornecer dados essenciais sobre os alvos, como sua localização, elevação, biomassa, temperatura, umidade, entre outros. O SR possui vantagens em relação a outras formas de coleta de dados, sendo não invasivo e fornecendo informações em tempo real NONATO; ABREU, (2020).

Nesse sentido, os sistemas de sensoriamento remoto foram desenvolvidos com vistas ao atendimento das diferentes demandas dos usuários, ou seja, objetivando o fornecimento de imagens que possuíssem características geométricas, espectrais e temporais distintas. Em vista disso alguns usuários podem preferir imagens tomadas em várias bandas como é o caso do

mapeamento agrícola, onde as imagens de SR podem ser produzidas a partir de sensores embarcados em plataformas orbitais, terrestres e aéreas, a exemplo os sensores das câmeras dos UAVs (MOLIN et al., 2015).

Liu (2006), destaca que uma imagem de sensoriamento remoto pode provir da energia artificial, produzida a partir do próprio satélite que teve seu direcionamento para a superfície terrestre e após isso captada pelo sensor; é o que ocorre por exemplo com as imagens de radar (do inglês Radio Detection and Ranging), ou Lidar (do inglês Light Detection and Ranging). As etapas que compreendem o processo de obtenção e distribuição das imagens são descritas na fig. 02, onde parte da radiação solar que incide na superfície da terra é refletida de volta para o espaço e é captada pelo satélite, assim, os dados da imagem redirecionam-se por meio de telemetria para as estações (ZANOTTA et al., 2019).

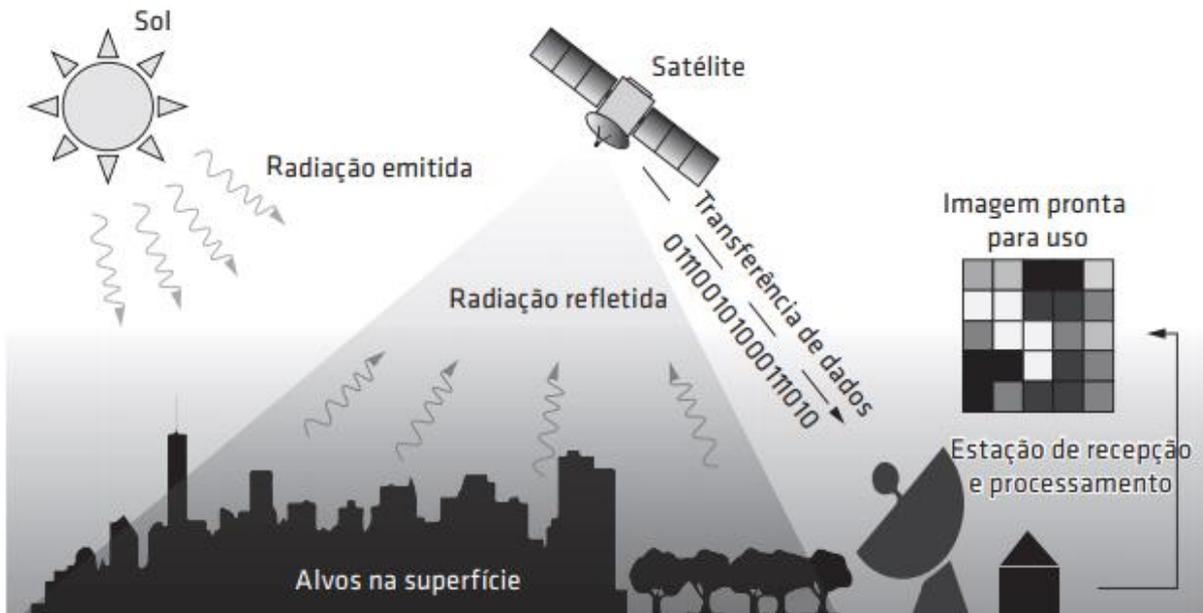


Figura 02: Etapas do processo de obtenção e distribuição das imagens de SR. Fonte: Adaptado Zanotta (2019).

As imagens digitais são formadas a partir de um grupamento de pixels (picture elements) que caracterizam a quantidade de energia que deixa uma porção definida da superfície. Assim, a energia eletromagnética é definida sobre formas de diferentes comprimentos de ondas; a partir desse entendimento inicial que é possível realizar a interpretação dos alvos da superfície com base na quantidade de radiação que foi refletida ou emitida por eles (SILVA, 2019).

Nesse sentido, a radiação eletromagnética REM trata-se do transporte de energia através de flutuações dos campos elétrico e magnético, onde é possível obter informações de temperatura, composição química bem como a movimentação do alvo, no caso as áreas agrícolas, por meio do estudo e interpretação da radiação que eles refletem. Vale destacar que a radiação

eletromagnética pode ser considerada a partir de diversas formas uma vez que existem diferentes comprimentos de onda, fig. 03, desse modo o espectro eletromagnético é dividido em faixas que possuem limites sensivelmente precisos, denominadas de: visível, infravermelho, ultravioleta (UV), ondas rádio etc. As ondas eletromagnéticas se propagam na mesma velocidade da luz, salvo a luz visível, todas são imperceptíveis a olho nu (GREGORIO, 2000).

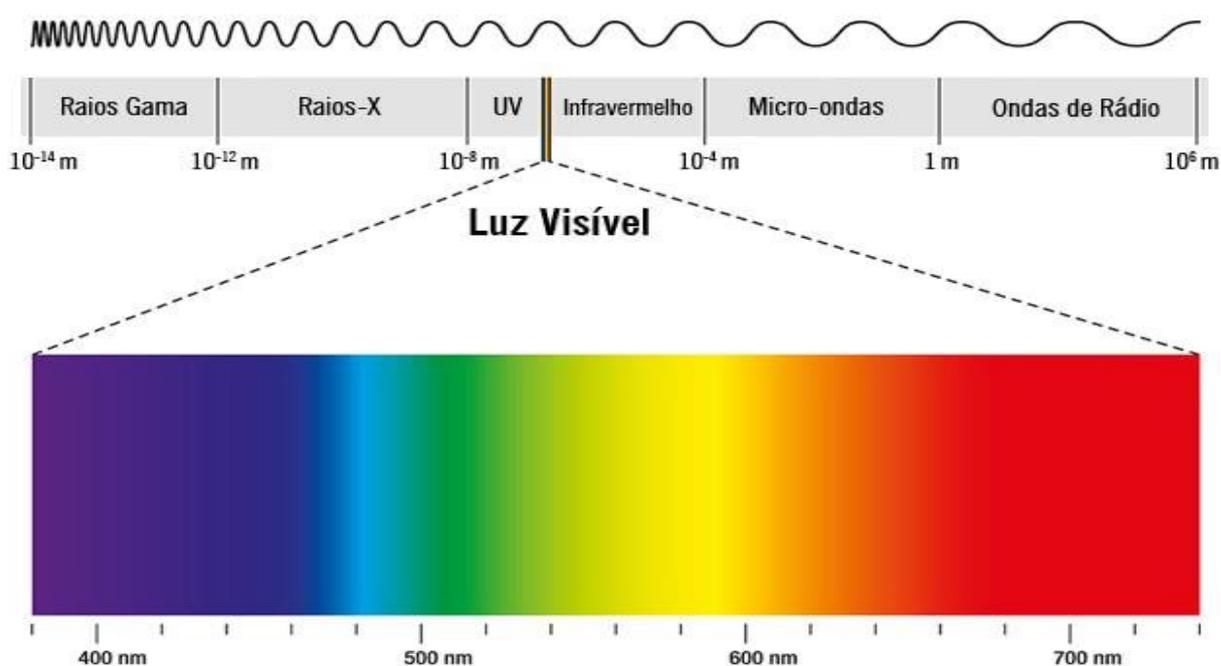


Figura 03: Ondas eletromagnéticas e espectro eletromagnético. Fonte: Adaptado de Giovanini (2022)

Ressalta-se que a curva espectral característica de vegetação possui baixa reflectância na região visível do espectro eletromagnético e alta reflectância na região do infravermelho próximo, e no que tange ao comprimento das ondas eletromagnéticas, as faixas mais empregadas no setor agrícola são do espectro visível e do infravermelho próximo. Desse modo, associa-se dados de refletância com as características das plantas, que compreendem o índice de área foliar, a biomassa, etc. (SHIRATSUCHI et al., 2014).

Na faixa que compreende a região do visível (vermelho, verde e azul), quando se trata das plantas, a maior parte da radiação emitidas sobre o dossel delas é absorvida pelos chamados pigmentos fotossintéticos que são as clorofilas a e b, os carotenoides e as ficobilinas, xantofilas e antocianinas, esses são responsáveis pela regulação do comportamento espectral da vegetação (SOUZA, 2021).

Já na faixa da região do infravermelho, os pigmentos não têm controle significativo sobre a refletância das folhas, conforme apontado por Andrade (2018). Nessa região, a forma como a radiação de comporta, depende das estruturas celulares internas, que comumente tem

contribuição do conteúdo de água na folha. Assim, nessa região, a absorção é muito baixa (menos de 15%) e a refletância pode chegar até 50% (TUCKER; GARRATT, 1977).

Nesse sentido Maimaitijiang et al. (2020), afirma que a vantagem do SR sobre a agricultura, é permitir o monitoramento em tempo real do desenvolvimento fenológico das culturas, bem como, contribuir com as estimativas de biomassa, etc., o que auxilia os agricultores nas tomadas de medidas preventivas, visando o aumento e produtividade de suas lavouras.

3.4 Satélites

3.4.1 Landsat-8

O satélite Landsat-8 foi desenvolvido a partir de uma parceria entre a NASA e o US Geological Survey (USGS), e teve seu lançamento em 11 de fevereiro de 2013. Ele transporta os sensores Operacional Land Imager (OLI) e o de Infravermelhos Térmicos (TIRS), por meio dos quais é possível coletar dados de bandas espectrais de infravermelho próximo, visível e infravermelho de ondas curtas. Esses dois sensores possuem resolução espacial de 30 metros (visível, NIR, SWIR); 100 metros (térmico); e 15 metros (pancromático) conforme as descrições da fig. 05 (PARANHOS FILHO et al., 2021).

Tabela 01: Informações do satélite Landsat-8.

Bandas	Comprimento de ondas (nm)	Resolução espacial (m)
B1-costal aerosol	430-450	30
B2-azul	450-510	30
B3-verde	530-590	30
B4-vermelho	640-670	30
B5-NIR (Infravermelho Próximo)	850-880	30
B6-SWIR 1	1570-1650	30
B7-SWIR 2	2110-2290	30
B8-pacromática	500-680	15
B9- cirrus	1360-1380	30

Fonte: Adaptado de (RODRIGUES et al., 2016).

3.4.2 Sentinel-2

A missão Copernicus Sentinel-2 compreende uma constelação de dois satélites, o Sentinel-2A e Sentinel-2B que são equipados com Instrumentos Multiespectrais (MSI) capazes

de adquirir informações de 13 bandas em diferentes resoluções espaciais: 10m, 20m e 60m, conforme mostradas na tabela 02, ademais, possui período de revisita de cinco dias. O satélite Sentinel - 2 fornece dados mais acurados a cerca dos detalhes na faixa de banda NIR e faixa de banda SWIR, o que é útil para aplicações de agricultura por exemplo (ZHANG et al., 2017).

Tabela 02: Informação espectral e resolução espacial do Sentinel-2.

Resolução	Nº da bandas	Nome das bandas	Comprimento de onda (µm))	Combinações de bandas
10	B02	Blue (Azul)	490	Cor Verdadeira RGB 04/03/02 Falsa Cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20	B05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	
60	B01	Aerosol	443	-
	B09	Water Vapor	940	
	B10	Cirrus	1375	

Fonte: Adaptado de CASELLA (2018).

3.4.3 Planet Scope

O satélite Planet Scope, lançado em junho de 2016, consiste em uma constelação de mais de 200 nanossatélites que fornecem dados de observação da Terra com alta precisão. Ele é equipado com o sensor Optica-VHR1/2, capaz de capturar imagens de 3 metros de resolução espacial. Segundo Sannier et al. (2019), esse sensor oferece alta resolução e possibilita o acesso a imagens diárias. Os satélites dessa geração possuem 8 bandas, incluindo Coastal Blue, Green I e Red-Edge, conforme especificado na Tabela 03 (SCCON, 2022).

Tabela 03: Informações do Planet Scope.

Bandas	Comprimento de onda (nm)	Resolução espacial (m)
B1	431-452	Coastal blue (Azul Costal)
B2	465-515	Blue (Azul)
B3	513-549	Green I (Verde I)
B4	547-583	Green (Verde)
B5	600-620	Yellow (Amarelo)
B6	650-680	Red (Vermelho)
B7	697-713	RedEdge (Borda do Vermelho)
B8	845-885	NIR (Infravermelho Próximo)

Fonte: Adaptado de Scon (2022).

3.4.4 Veículos Aéreos não Tripulados

Os veículos aéreos não tripulados (UAVs), também conhecidos como drones, são umas das tecnologias utilizadas no sensoriamento remoto agrícola mediante técnicas de agricultura digital. Os UAVs, através de câmeras embarcadas com sensores RGB ou multiespectral, são capazes de recolher imagens com alta definição, uma vez que cada um deles possui um filtro de alta qualidade, específico para captação de diversos formatos de ondas refletidas, o que permite a separação em diferentes tipos de cores, além de captar frequências como o infravermelho, que é imperceptível a olho nu (HOTT et al., 2019).

Nesse sentido, os drones podem ser usados para superar lacunas deixadas pelo sensoriamento remoto por satélite, por exemplo com relação a grande escala espacial, longos períodos de revisita, etc. Os tipos de UAVs podem ser utilizados em análises de imagens, monitoramento do solo e análise detalhada da situação de uma cultura.

O drone (Quad Copter), multimotor de asa rotativa possui quatro rotores que sustentam a esse modelo, conforme mostra a fig. 04 em que, dos quatro rotores, dois são posicionados de modo oposto e giram no sentido horário, e os outros dois rotores restantes giram no sentido anti-horário (ZHANG et al., 2021).

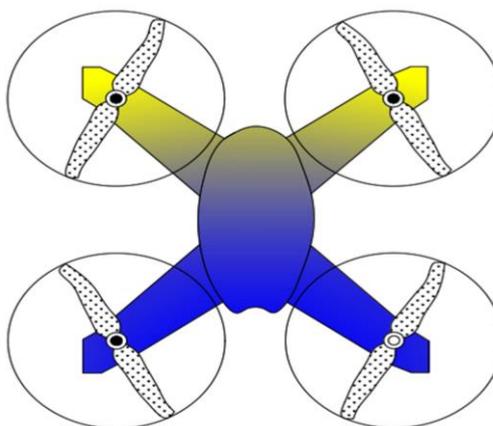


Figura 04: Quad copter. Fonte: (VELUSAMY et al., 2021)

O movimento que ocorre em torno do eixo que inclui movimentos para frente e para trás é conhecido por “pitch”, quando se move lateralmente nas direções esquerda ou direita é chamado de “rol” e os movimentos no sentido horário e anti-horário chamados “yaw”. Nessa perspectiva as imagens dos veículos aéreos não tripulados ganham destaque e vêm sendo cada vez mais utilizadas no mapeamento de variações de crescimento e previsão de produção na agricultura (VELUSAMY et al., 2021).

Sob essa óptica, os drones podem ser operados de duas formas: manual ou automatizada, executando voos pré-programados. Assim os planejamentos de voos com finalidades agrícolas são executados de forma automatizada, para isso há inúmeras plataformas, dentre elas a DJI Ground Station Pro[®] (QUEIROZ et al., 2021).

3.5 Ferramentas de Processamento Digital de Imagens

Atualmente existe uma diversidade de softwares de SIG (do inglês Geographical Information System, GIS), que tem por finalidade analisar e interpretar dados geoespaciais bem como realizar o processamento de imagens, alguns são livres, como é o caso por exemplo do Quantum GIS (Q-GIS[®]), por meio do qual é possível gerar, observar, administrar, editar e analisar dados, ademais, permite que se faça layout de mapas que são exportáveis em diferentes formatos (PEREIRA, et al., 2018).

Nessa perspectiva, existe também uma plataforma de computação em nuvem, o Google Earth Engine (GEE), que através de scripts digitados em navegadores é possível acessar um catálogo de várias imagens de satélite e conjuntos de dados geoespaciais, incluindo todo o catálogo Landsat do EROS (USGS / NASA), Sentinel-2, Planet Scope, o que permite uma grande variedade de aplicação que vão desde a agricultura até dados de precipitação, elevação,

etc. Essa plataforma de computação possui alto desempenho, fator que contribui para que muitas das limitações relacionadas com os dados de download, armazenamento e processamento, que normalmente ocorrem quando grandes quantidades de dados são analisadas, sejam superadas sem esforços (RAVANELLI et al., 2018).

3.6 Comportamento Espectral da Vegetação

As plantas possuem um comportamento espectral característico, com baixa refletância na região do espectro visível que se dá pela maior absorção de clorofila; alta refletância na faixa do infravermelho próximo (NIR), em decorrência da dispersão interna das folhas e absorção de clorofila; possui ainda, refletância mais baixa no infravermelho devido a forte absorção por água, conforme indicado na fig. 06 (SILVA, 2020).

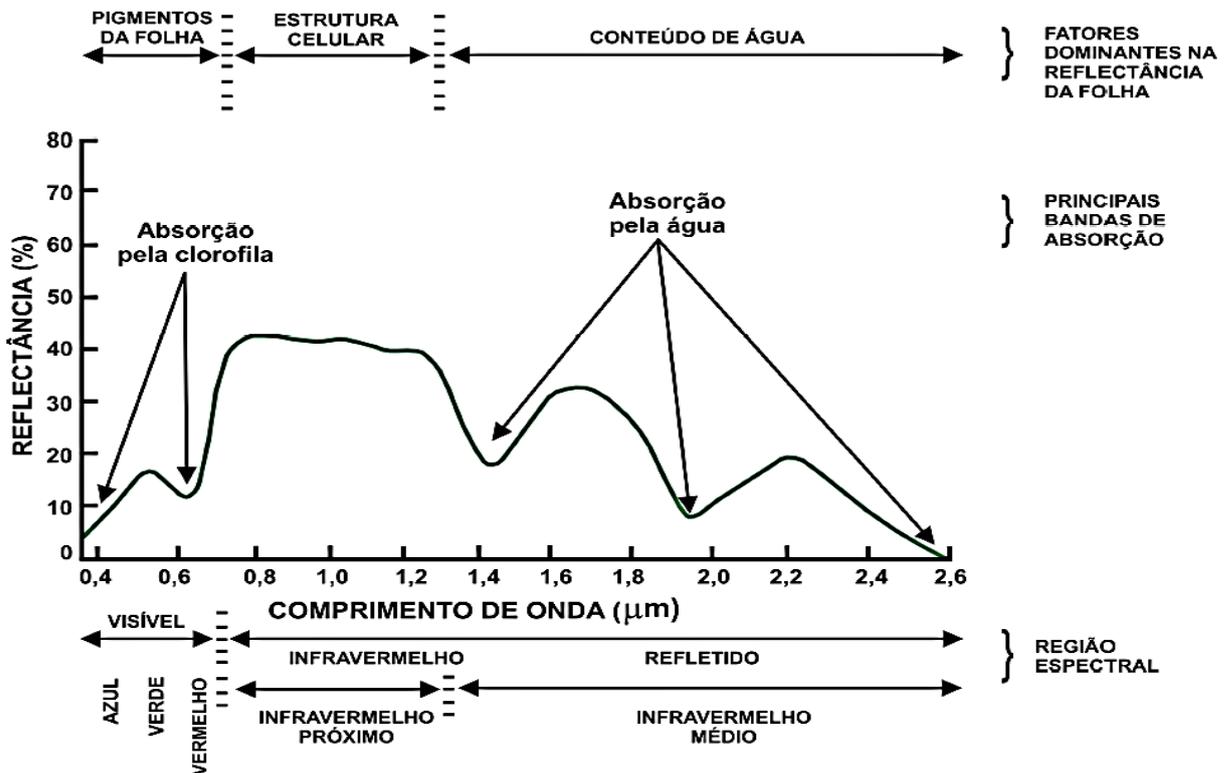


Figura 05: Reflectância de uma folha sadia. Fonte: Adaptado de (SILVA, 2020).

O único componente provável de absorver a radiação que provém da faixa do vermelho é a clorofila, já na região do infravermelho próximo a absorção ocorre de forma inferior. Nesse sentido, uma parte da radiação eletromagnética é espalhada internamente, e varia de acordo em decorrência das características fisiológicas da folha (ABREU JÚNIOR, 2019).

3.7 Índices de Vegetação

Os Índices de Vegetação (IVs) são medidas radiométricas adimensionais e têm grande importância nas aplicações do sensoriamento remoto na agricultura, uma vez que indicam, através de combinações matemáticas, os parâmetros relacionados aos aspectos biofísicos da cobertura vegetal, como a quantidade relativa e a atividade fotossintética da vegetação verde, o que inclui o índice de área foliar (IAF), percentual de cobertura verde, teor de clorofila, biomassa verde, etc. Ressalta-se que os IVs apresentam diferentes finalidades que se complementam, para avaliar o desenvolvimento das culturas (ACHAPARINI et al., 2019).

3.7.1 NDVI

O Normalized Difference Vegetation Index (NDVI) ou Índice de Vegetação da Diferença Normalizada tem a finalidade de produzir um índice espectral que dissocia a vegetação verde do brilho do solo de fundo, para tanto, utiliza-se modelos matemáticos, ou algoritmos baseados em SR e dados digitais de sensores embarcados em satélites ou aeronaves remotamente pilotadas. Assim é possível determinar a biomassa foliar fotossinteticamente ativa por unidade de área, ou seja, quanto maior os valores de NDVI, mais densa é a biomassa foliar (FREITAS et al., 2022).

Nesse sentido o NDVI é razão entre a diferença das reflectâncias da banda do infravermelho próximo (NIR) e do vermelho (RED) pela soma dessas mesmas bandas conforme indicado pela equação 01 (ANABITARTE et al., 2020).

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (1)$$

Os valores do NDVI, calculados utilizando a equação mencionada, variam de -1 a +1. Valores próximos a +1 indicam alta cobertura vegetal, enquanto valores positivos, mas não muito elevados, podem representar solo nu, vegetação rala ou estágios vegetativos avançados em culturas agrícolas.

Áreas alagadas apresentam valores negativos próximos a -1, enquanto nuvens refletem de forma semelhante nas bandas visíveis e infravermelhas próximas, resultando em valores de pixel próximos a zero. A figura 06 mostra a escala de valores e as cores correspondentes ao NDVI (Anabitarte et al., 2020)



Figura 06: Escala de valores e as cores correspondentes ao NDVI. Fonte: (ANABITARTE et al., 2020).

3.7.2 NDRE

O Normalized Difference Red-Edge (NDRE) ou Índice de Vegetação por Diferença Normalizada na Borda do Vermelho, é capaz de medir a quantidade de clorofila foliar nas plantas e fornecer uma resposta mais precisa. A banda RedEdge possui a capacidade de detectar alterações no conteúdo da clorofila dentro da folha e em toda a copa das plantas, assim o NDRE apresenta resultados mais eficientes quando as plantas se encontram em estádios vegetativos mais avançados, ou seja, quando a saturação do NDVI está presente (NAGUIB; DALIMAN, 2022).

Assim o NDRE é representado pela razão entre a diferença das reflectâncias das bandas do NIR (infravermelho próximo) e do RedEdge (borda do vermelho) pela soma dessas mesmas bandas conforme indicado pela equação 02, os seus valores variam de -1 a 1 (EITEL et al., 2011).

$$NDRE = \frac{(NIR - RedEdge)}{(NIR + RedEdge)} \quad (2)$$

O NDRE, além de permitir a avaliação do vigor vegetativo das plantas, possibilita ainda que se faça a identificação e diferenciação entre áreas com presença de cobertura vegetal e solo. Outra característica desse índice é a sua capacidade de direcionar a evolução de biomassa das mais variadas culturas no decorrer do ciclo, permitindo a relação dos valores do acúmulo de biomassa aos resultados de produtividade (KLERING et al., 2016).

3.7.3 GLI

O Green Leaf Index (GLI), ou Índice de Folha Verde foi desenvolvido para realizar a determinação das áreas plantadas levando em consideração o espectro visível das bandas de imagens RGB. Os seus valores compreendem em intervalos de -1 a +1, onde os valores negativos representam solo exposto, planta morta ou estágios vegetativos avançados, enquanto os positivos caracterizam a vegetação verde, saudável. Assim, o GLI é representado pela equação 4 (OZTURK; ÇOLKESEN, 2021).

$$GLI = \frac{(2 * GREEN - RED - BLUE)}{(2 * GREEN + RED + BLUE)} \quad (3)$$

Nesse contexto, Silva (2020) afirma que o GLI apresenta resultados bastantes robustos no que tange a avaliação de culturas, podendo ser utilizado como indicativo de alterações na

vegetação, visto que tem apresentado ótimas correlações com as mudanças na clorofila das folhas.

3.7.4 VARI

O Visible Atmospheric Resistance Index (VARI) ou Índice Resistente à Atmosfera na Região Visível, tem a capacidade de identificar e detectar alterações na vegetação e outra característica desse índice é a sua sensibilidade á quantidade de clorofila nas folhas. É possível, por exemplo, obtê-lo por meio de cálculos das bandas do visível RGB de imagens capturadas por VANTs (MAIA, 2019).

De acordo com Eng et al. (2019), a equação 5 é utilizada na estimativa de vegetação com uma sensibilidade mínima aos efeitos da atmosfera. A adição de dados da banda azul serve para minimizar os efeitos atmosféricos, podendo estimar a fração de vegetação com erro inferior a dez por cento.

$$VARI = \frac{(GREEN - RED)}{(GREEN + RED - BLUE)} \quad (4)$$

O VARI, por possuir essa particularidade de levar em consideração a influencia dos constituintes atmosféricos, é bastante utilizado para realizar a estimativa de vegetação verde por meio da faixa do visível do espectro eletromagnético, o que possibilita a análise da lavoura em todos os seus estádios vegetativos, no entanto, o melhor desempenho se dá nas fases em que a planta está com maior Índice de Área Foliar (IAF) (ANDRADE et al., 2019).

4 MATERIAL E MÉTODOS

4.1 Caracterização da Área de Estudo

O estudo ocorreu em uma lavoura comercial de soja localizada em Buriti - MA, (fig. 08). Está situado nas coordenadas geográficas de latitude $3^{\circ} 56' 34''\text{S}$ e longitude $42^{\circ} 55' 36''\text{W}$, com altitude de 103 m (IBGE, 2023).

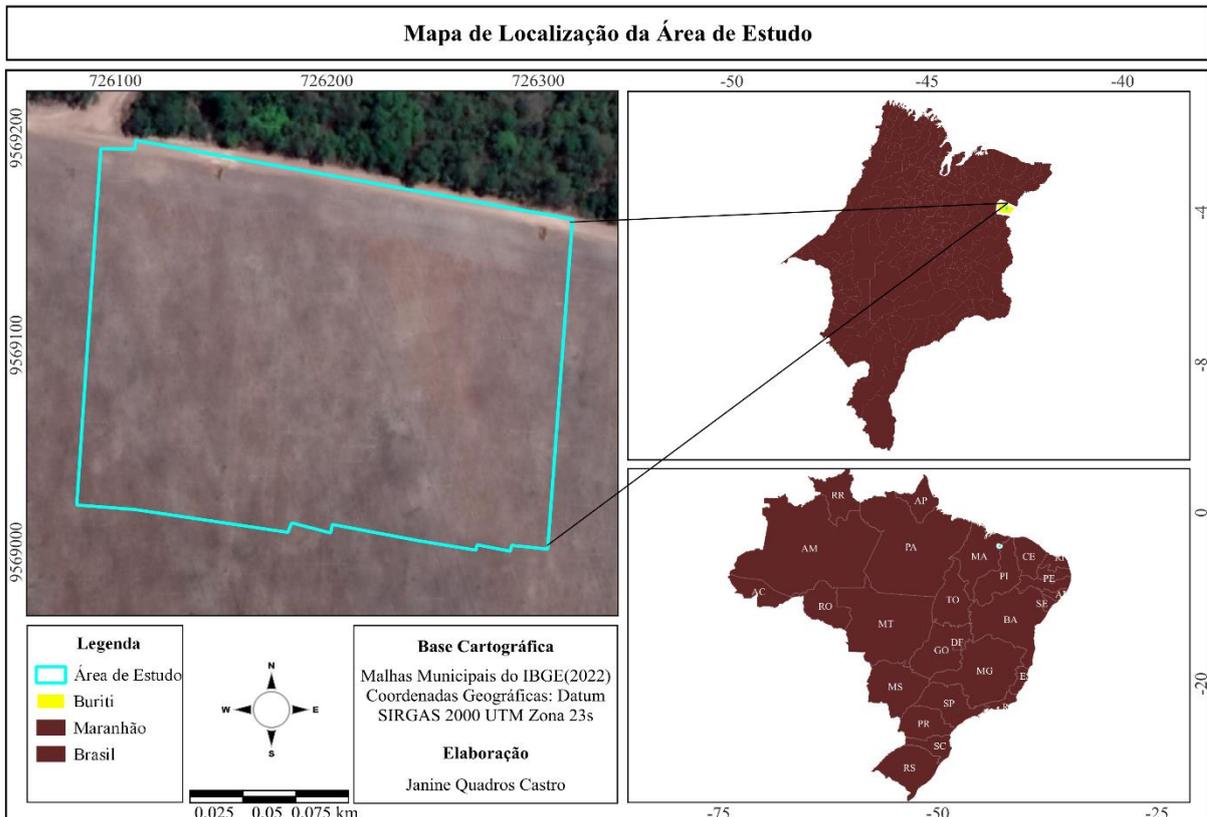


Figura 07: Mapa de localização da área de estudo, Buriti, MA, Brasil.

Conforme aponta os estudos de Araujo et al. (2002) a região é abrangida pelo bioma cerrado, com predominância do relevo Barreiras, e o tipo de solo é o argissolo. De acordo com a classificação climática de Koppen-Geiger, o clima na área é caracterizado como CWA, sendo um clima tropical úmido com estação chuvosa durante o verão e seca no inverno. A média anual de temperatura é de $27,9^{\circ}\text{C}$, e a precipitação anual atinge valores médios anuais de 1.613,2 mm (PASSOS, 2017).

A seguir, estão apresentadas as etapas metodológicas empregadas no levantamento, mapeamento e monitoramento da saúde da lavoura estudada (fig. 08).

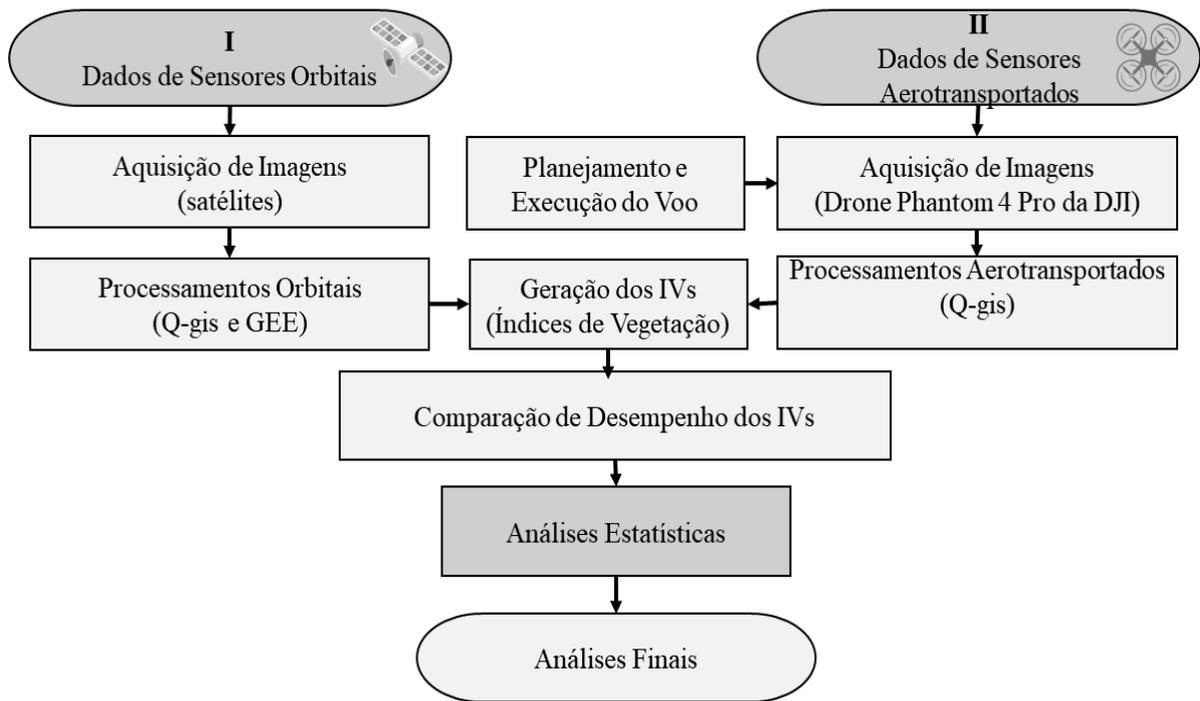


Figura 08: Etapas metodológicas empregadas na obtenção e tratamento dos dados. Fonte: Autor

4.2 Aquisição e Processamento dos Dados de Sensores Orbitais

No processo de aquisição das imagens foram utilizados os produtos dos satélites Planet Scope, Landsat 8 e Sentinel-2, foi realizado o processamento e análise dos dados por meio do software Q-GIS (Quantum GIS) e a plataforma GEE (Google Earth Engine) que é uma ferramenta que oferece recursos avançados para armazenamento e processamento de imagens de satélites, além de possuir velocidade de processamento mais rápida que as técnicas convencionais de SIG e permite a utilização de técnicas de programação (SANTOS, 2022).

Para filtrar as datas e selecionar apenas as imagens de satélite correspondentes ao período em que houve a realização do voo com o drone na lavoura estudada, foi utilizado um código em Javascript, que pode ser acessado através do endereço: [<https://code.earthengine.google.com/0e5bec65973bb15b0b104d30ec7dcc9b>]. Com as imagens selecionadas, calculou-se os valores médios e máximos dos índices NDVI, NDRE e VARI para cada pixel.

É importante ressaltar que as imagens dos satélites Sentinel (2) e Landsat(8) não estavam disponíveis na mesma data em que o voo com o drone foi realizado. Devido a essa indisponibilidade, foram baixadas imagens que se aproximavam o máximo possível da data do levantamento. Essa abordagem foi adotada para permitir uma comparação mais consistente entre os dados obtidos pelo drone e os dados dos satélites, levando em consideração a

temporalidade das informações.

Para eliminar variações abruptas nos índices de vegetação causadas por nuvens, foi aplicada uma máscara de nuvens. Em seguida as imagens foram exportadas no formato GeoTIFF para uma pasta no Google Drive e posteriormente adicionadas como camada Raster ao Q-gis para geração dos mapas correspondentes aos índices de vegetação estudados. Foi definida também o tipo de renderização das imagens como "banda simples falsa-cor" e por meio da ferramenta "reporta raster de valor único", os valores correspondentes aos índices foram exportados em formato "xlsx" para o Excel. Após isso obteve-se histogramas que mostram a frequência com que valores dos IV's ocorrem em diferentes faixas.

Gerou-se também os diagramas de caixa (BoxPlot) como parte da análise dos índices de vegetação. Através desses gráficos foi possível visualizar e comparar a distribuição dos valores, incluindo os quartis, valores mínimos, máximos e a identificação de outliers. Assim foi possível observar as diferenças e semelhanças entre os índices de vegetação e também entre as fontes de dados, como os satélites e UAV.

4.3 Aquisição e Processamento dos Dados de Sensores Aerotransportados

A seguir, pode-se observar o fluxograma com as etapas metodológicas empregadas no processo de aquisição e processamento dos dados do sensor aerotransportado (fig. 09).

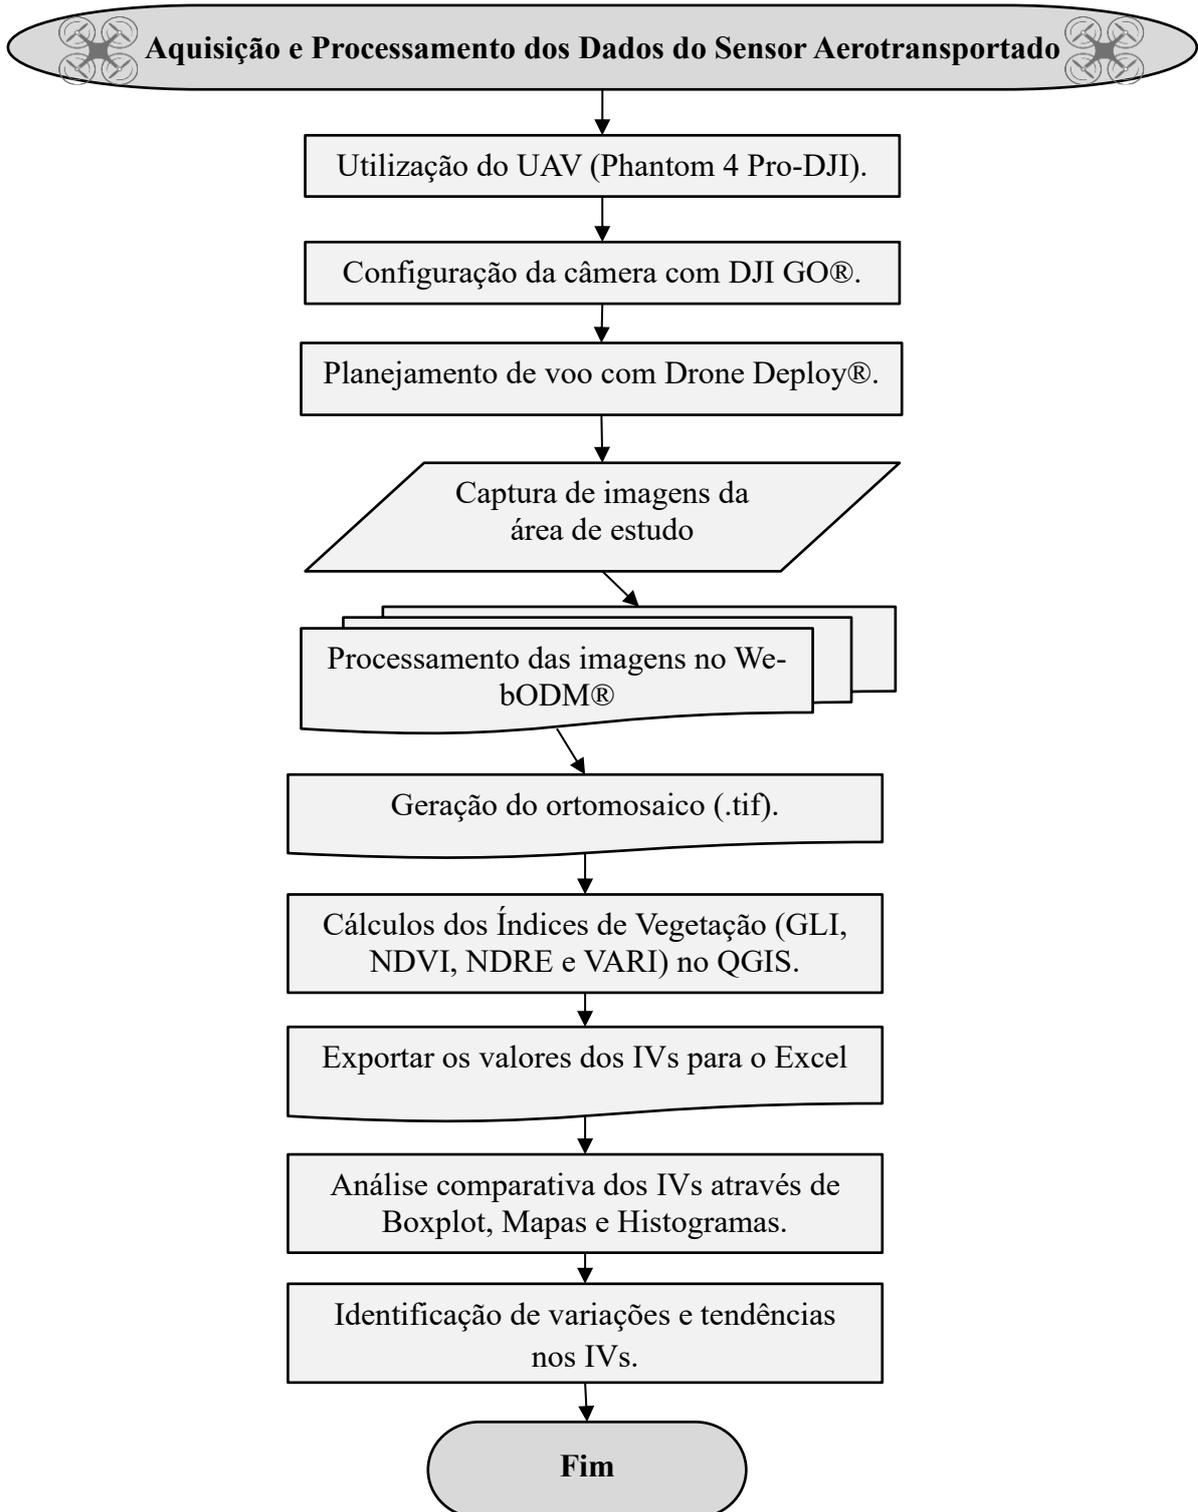


Figura 09: Fluxograma de aquisição e processamento dos dados do sensor aerotransportado. Fonte: Autor

Para a aquisição de imagens, utilizou-se o Phantom 4 Pro, um modelo avançado de Unmanned Aerial Vehicle (UAV) fabricado pela DJI (fig.10). Esse drone possui recursos sofisticados de voo automatizado, incluindo um sistema de GPS integrado que garante voos precisos e estáveis. Equipado com uma câmera FC6310, estabilizada de gimbal de três eixos e

um sensor CMOS de 1" com resolução de 20 megapixels, o Phantom 4 Pro oferece imagens de alta qualidade e nitidez (DJI, 2023).



Figura 10: Phantom 4 Pro Fonte: Google Imagens

As imagens obtidas por meio do UAVs foram utilizadas para gerar mapas temáticos e aplicar índices vegetativos que permitiram uma análise detalhada e o monitoramento eficiente da lavoura. Assim, a calibração do equipamento (fig. 11) e coleta das imagens foram realizados durante o período compreendido entre as 10h e 14h, levando-se em consideração as condições meteorológicas favoráveis que proporcionassem uma iluminação adequada para a obtenção de fotos bem iluminadas.



Figura 11: Manuseio e calibração do Phantom 4 Pro.

No planejamento do voo, foi empregado o software Drone Deploy® para coordenar e controlar as operações de captura de imagens. Além disso, para a configuração da câmera, utilizou-se o software DJI GO®, conforme indicado por Andrade Junior (2021).

O drone foi utilizado para cobrir toda a área de estudo, que corresponde a 2,53 ha. Com

uma altitude de voo: 62,6 m, foram capturadas 70 imagens no dia 02 de maio de 2022. Nessa data, a cultura da soja encontrava-se a 114 dias de pós-semeadura, no estágio vegetativo R8. Indicando a sua maturação plena, uma vez que a variedade de soja utilizada (Pampeana 9510 IPRO) possui ciclo médio de 122 dias. Esses detalhes forneceram insights importantes tanto para a interpretação dos resultados como para compreensão do impacto do estágio de desenvolvimento da soja nas análises realizadas.

O software Drone Deploy foi essencial para realizar o voo autônomo e capturar imagens da área de estudo. Com ele, foi possível criar um plano de voo personalizado, monitorar a velocidade do drone, a altura de voo e o número de fotos capturadas, levando em consideração os limites da propriedade (fig.12). O uso desse software simplificou todo o processo de levantamento aéreo, garantindo a captura de imagens de alta qualidade para análise e processamento posterior.

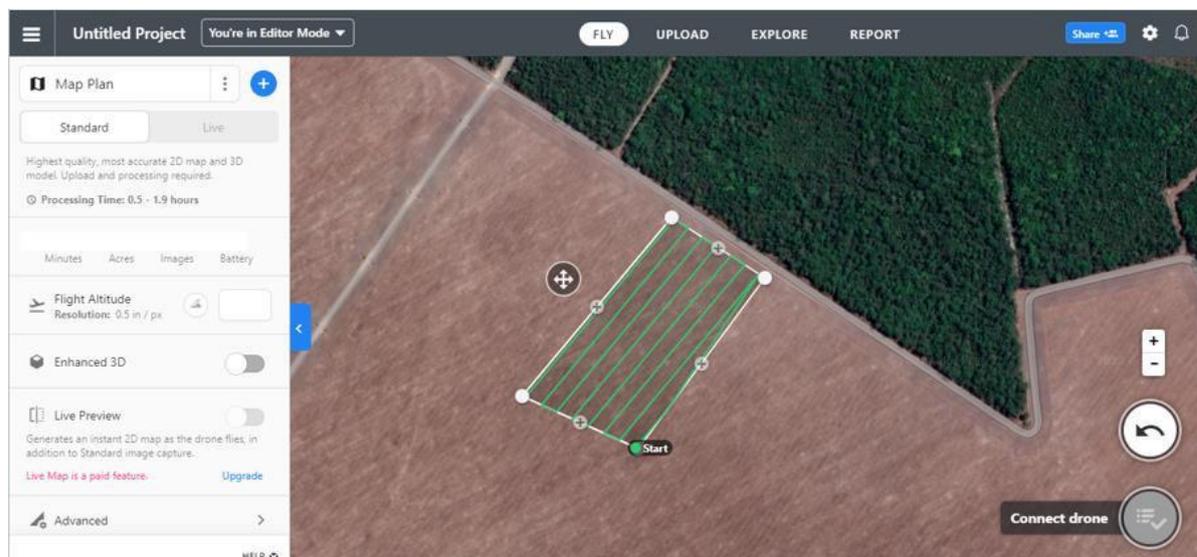


Figura 12: Plano de voo.

A fim de determinar a altitude de voo de 62,6 m, foram considerados vários fatores, incluindo a topografia da área e a presença de vegetação próxima, a fim de garantir a segurança e evitar colisões do drone. Além disso, foi estabelecida uma sobreposição de 80% no sentido frontal e 60% no sentido lateral durante o voo, garantindo uma cobertura adequada da área de estudo. Também foi avaliado o GSD (Ground Sample Distance), que representa a distância de amostragem do solo. Com um GSD de 3,33 cm/pixel, cada pixel nas imagens capturadas pelo drone representa uma área de 3,33 cm² no terreno. A câmera utilizada possuía um comprimento focal de 8,8 mm, o que indica uma lente capaz de capturar uma visão mais ampla da cena.

Utilizando a nuvem de pontos, composta por pontos tridimensionais representando as características do terreno, o ortomosaico (fig. 12) foi gerado diretamente no programa

WebODM, que possui recursos integrados para a criação de ortomosaicos, que são imagens georreferenciadas e corrigidas em relação à perspectiva, distorção e inclinação do terreno.

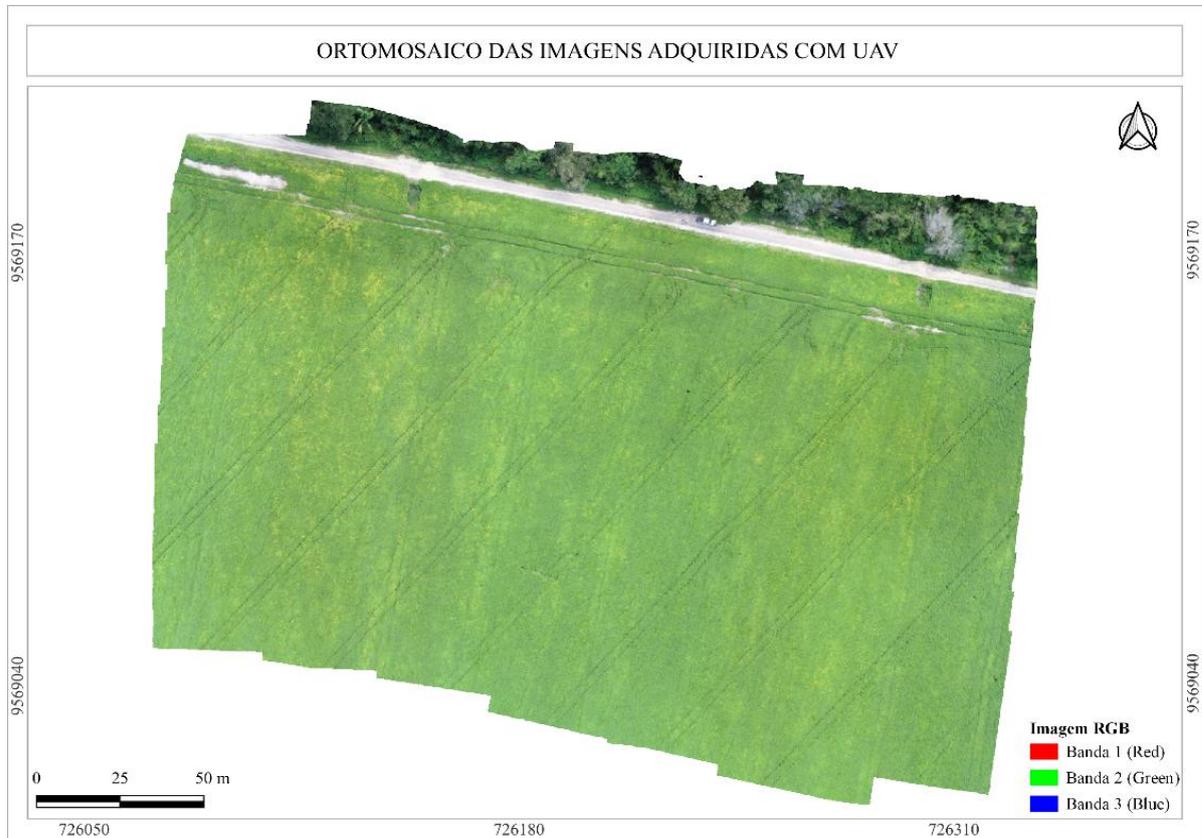


Figura 13: Ortomosaico da área de estudo.

O ortomosaico resultante do processamento foi exportado como arquivo com extensão “.tif”. Posteriormente serviu como base para a geração dos índices de vegetação, como o Índice de Luz Verde (GLI) e o Índice Resistente à Atmosfera na Região Visível, (VARI), no software QGIS. Após isso, os dados referentes aos valores dos pixels foram exportados por meio da ferramenta “reportar raster de valor único” em formato “.xlsx” para o Excel e gerados os indicadores estatísticos, como: média, mínimo, máximo, desvio padrão, coeficiente de variação (CV%), bem como histogramas e boxplot para cada índice analisado. Assim, foi possível realizar uma análise comparativa para identificar possíveis variações, tendências e consistências nos valores dos índices de vegetação, proporcionando informações valiosas sobre o desempenho de cada índice.

5 RESULTADOS E DISCUSSÕES

A análise estatística dos dados é apresentada na (fig. 13) por meio de um diagrama de caixa (Box Plot). Nesse gráfico, é possível visualizar as distribuições dos valores de NDVI provenientes das diferentes fontes de dados, incluindo imagens do UAV, dos satélites Sentinel (2), Landsat (8) e Planet Scope para a área de estudo.

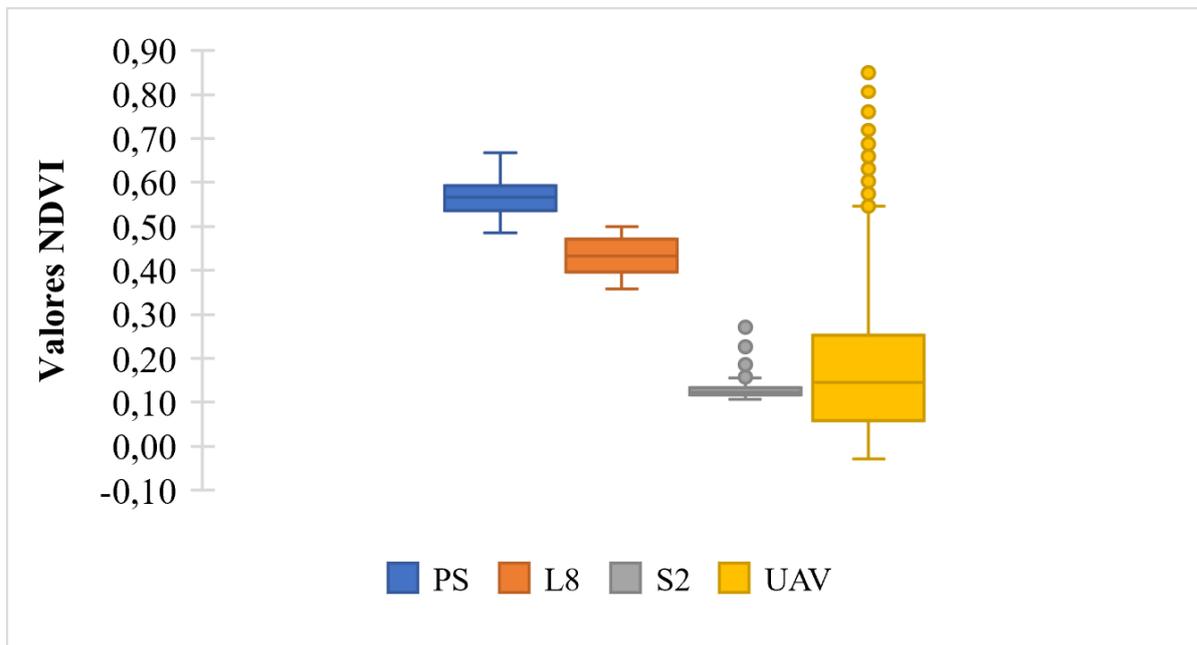


Figura 14: Boxplot dos valores NDVI das imagens do UAV, Sentinel (2), Landsat (8) e Planet Scope.

A distribuição do NDVI para a imagem UAV está concentrada entre 0.10 e 0.30, com a presença de outliers acima do valor máximo indicado. O Sentinel-2 apresenta uma distribuição concentrada entre 0.10 e 0.20, com presença de outliers. Já para o Landsat-8, a distribuição do NDVI concentra-se principalmente entre 0.40 e 0.50, sem a presença de outliers. Por fim, o Planet Scope mostra uma concentração principal entre 0.50 e 0.60, também sem outliers.

Ao se realizar a comparação, percebe-se que cada fonte de imagem possui uma distribuição ligeiramente diferente dos valores do NDVI. O UAV apresenta uma faixa mais ampla de valores, com a presença de outliers acima do máximo. O Sentinel-2, Landsat-8 e Planet Scope exibem distribuições mais concentradas, com presença de outliers apenas para o Sentinel-2. Assim, as medidas de posição, como a mediana, e variações representadas pelo intervalo interquartil (IQR) variaram entre as fontes de imagens, refletindo as diferenças nas características da área de estudo.

Assim, a fonte de imagens UAV apresenta características distintas nas distribuições dos valores NDVI, com variações na amplitude dos valores, ocorrência de outliers e diferenças nas medidas de posição e dispersão, como mediana e Intervalo Interquartil. Os dados obtidos das imagens de UAV mostram uma maior variabilidade nos valores dos índices vegetativos, conforme constatado nos estudos conduzidos por Souza (2020). Nesses estudos, foi concluído que, para todas as bandas espectrais e índices de vegetação analisados em diversos períodos, as imagens de satélite exibiram uma qualidade superior de processamento devido à menor variabilidade observada.

A análise das distribuições dos valores de NDRE provenientes do Sentinel-2 e Planet Scope (fig. 14) fornece informações sobre a variação dos valores de Ivs e características da área monitorada.

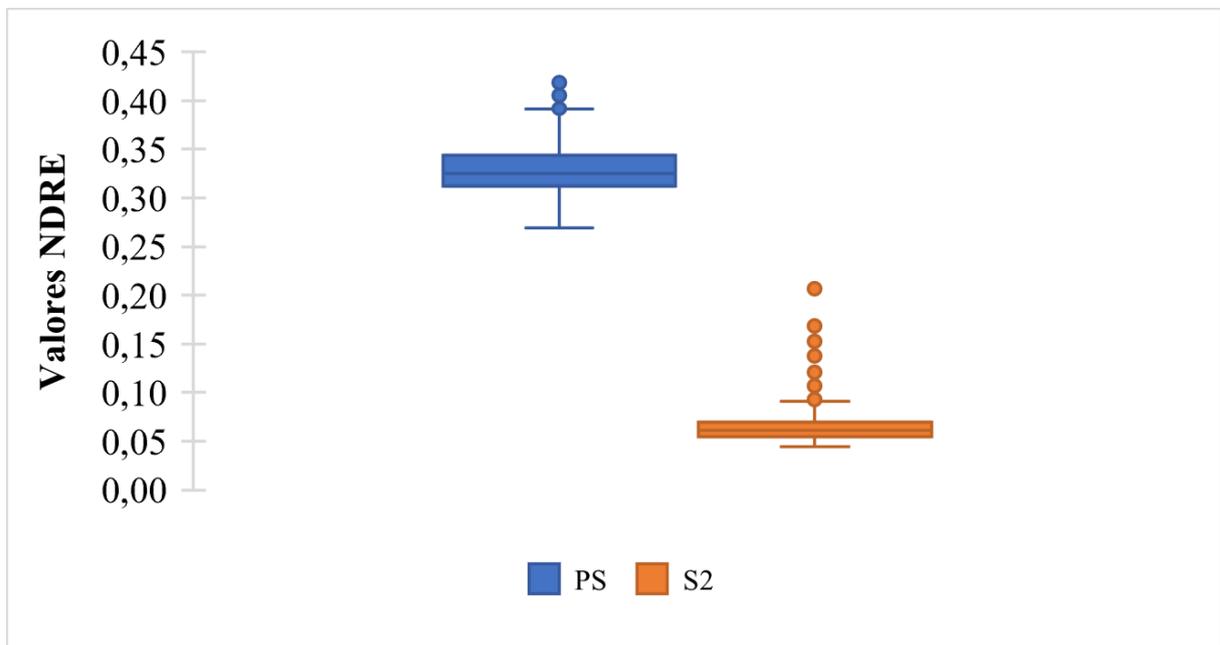


Figura 15: Boxplot dos valores NDRE das imagens do UAV, Sentinel-2, Landsat 8 e Planet Scope.

A distribuição do NDRE para o Sentinel-2 está concentrada em torno de 0.10, com a presença de outliers acima do valor máximo. A mediana, representada pelo 2º quartil (Q2), está centrada entre 0.05 e 0.10, indicando que metade dos dados estão nessa faixa. O intervalo interquartil (IQR), que é a diferença entre o 1º quartil (Q1) e o 3º quartil (Q3), está entre 0.05 e 0.10, sugerindo que a maioria dos dados está concentrada em um intervalo estreito.

Por outro lado, a distribuição do NDRE para o Planet Scope está concentrada principalmente em torno de 0.30 e 0.35, com a presença de outliers acima do valor máximo. No Sentinel-2, a mediana (Q2) é 0.32, indicando que metade dos dados estão nessa faixa ou um pouco abaixo dela. O intervalo interquartil (IQR) está entre 0.30 e 0.35, indicando uma

concentração estreita dos dados.

Através dessa comparação, fica evidente que os índices do Sentinel-2 e do Planet Scope apresentam distribuições concentradas, com medianas semelhantes e intervalos interquartis estreitos. No entanto, a existência de valores atípicos acima do valor máximo em ambas as fontes de imagens indica que há valores fora do intervalo normal dos dados. Além disso, o NDRE demonstrou sinais de saturação, resultado também encontrado por Marchioro (2023) em seus estudos.

Ao realizar a comparação dos índices VARI (Vegetation Index Ratio) para o UAV, Sentinel-2, Landsat-8 e Planet Scope, foi possível observar as distribuições dos valores do VARI (fig. 15) obtidos por cada fonte.

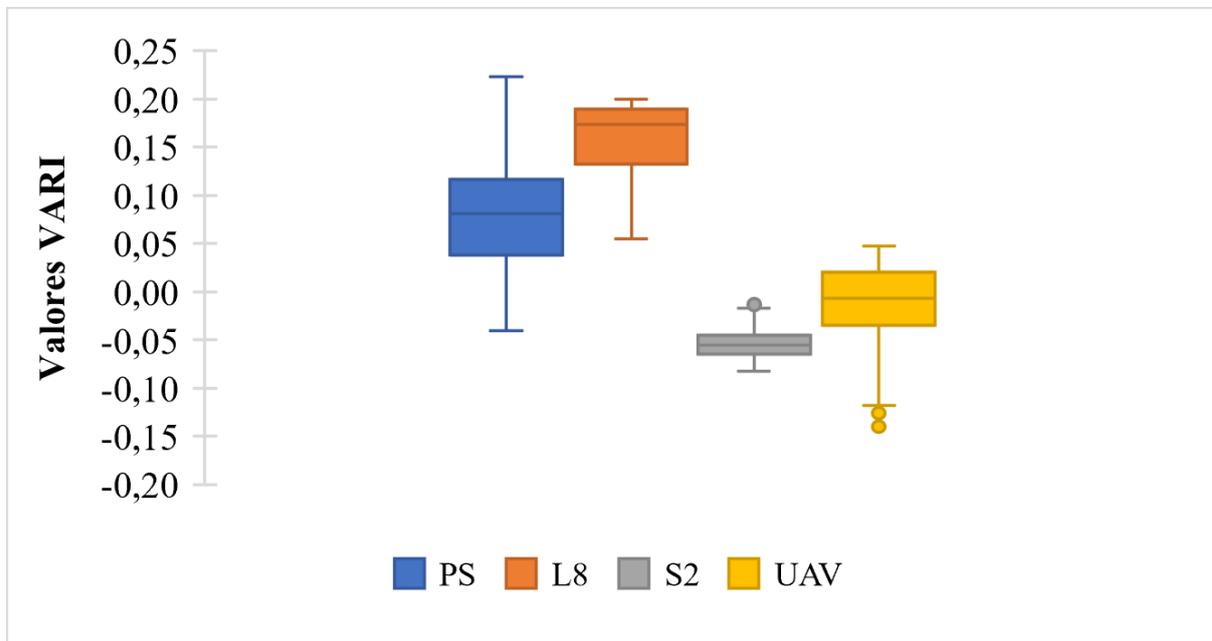


Figura 16: Boxplot dos valores VARI das imagens do UAV, Sentinel-2, Landsat 8 e Planet Scope.

Ao analisar o boxplot do UAV, observa-se que a distribuição está concentrada entre 0.00 e 0.05, com a presença de outliers abaixo do valor mínimo, o que indica uma faixa mais ampla de valores e valores extremos que estão abaixo do intervalo normal dos dados. Em relação ao Sentinel-2, a distribuição do VARI está concentrada entre -0.05 e 0.00, com presença de outliers acima do valor máximo. Já a distribuição do VARI para o Landsat-8 está concentrada entre 0.15 e 0.20, sem outliers. Assim, a mediana está próxima a 0.20. A distribuição do VARI para o Planet Scope está concentrada entre 0.05 e 0.15, sem presença de outliers.

Essa comparação revela que cada fonte de imagem apresenta uma distribuição diferente dos valores do índice VARI. O UAV possui uma faixa mais ampla de valores e valores extremos abaixo do intervalo normal. O Sentinel-2 e o Landsat 8 exibem distribuições mais concentradas,

sem valores extremos. Já o Planet Scope mostra uma distribuição concentrada sem valores extremos acima do intervalo normal.

Na (fig.16) é possível visualizar os mapas dos índices de vegetação NDVI/GLI, proveniente das fontes de dados UAV, Planet Scope, Sentinel e Landsat-8, onde é possível realizar comparação entre valores mínimos e máximos presentes nas imagens. O Planet Scope se destacou por apresentar uma amplitude maior nos valores do NDVI, com um mínimo de 0.5 e um máximo de 0.64, enquanto o UAV registrou um NDVI mínimo de 0.32 e um máximo de 0.5.

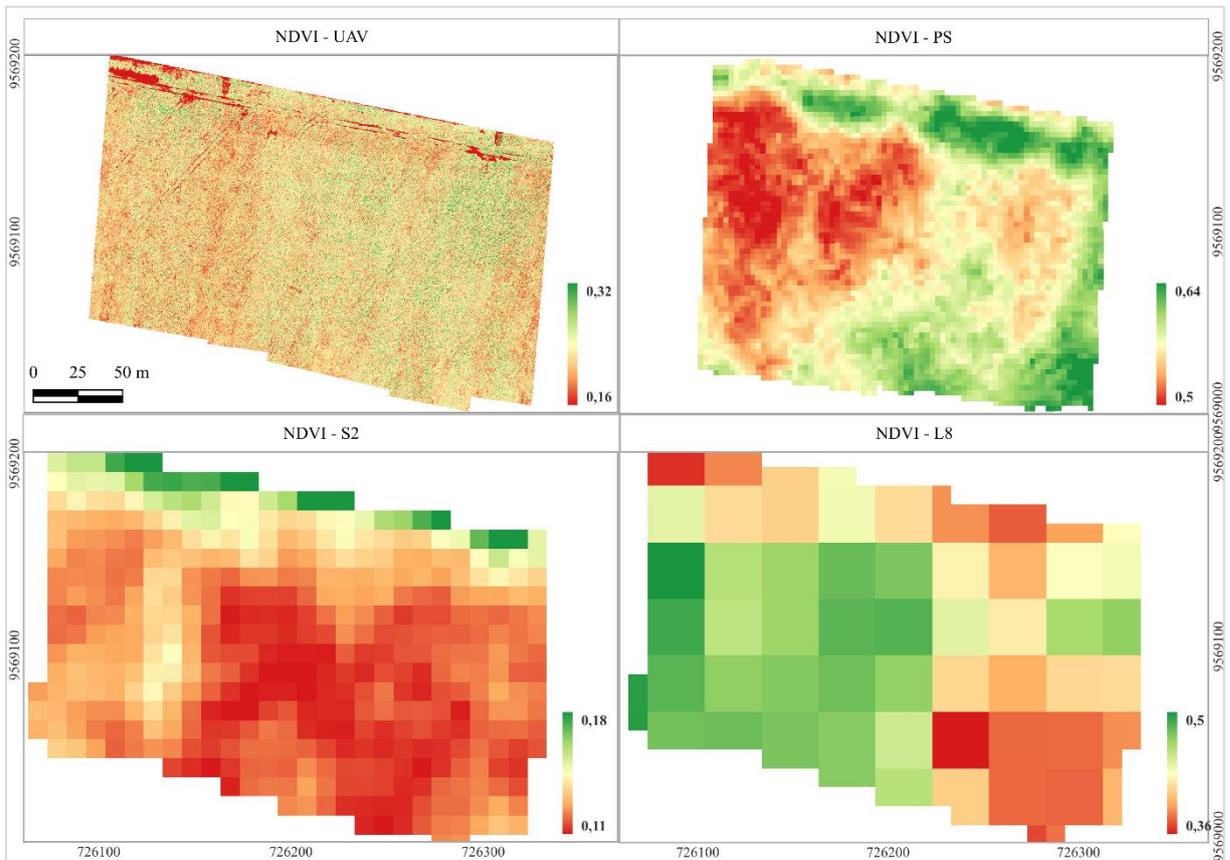


Figura 17: Imagens de NDVI dos dados orbitais aerotransportado.

Observado pela coloração em verde escuro na imagem, NDVI mais próximos de 1 e valores de NDVI mais em vermelho valores mais próximos -1. Kuiuawski et al. (2017) citaram que a soja acumula a maior taxa de fotoassimilados nos estádios intermediários de desenvolvimento com maiores valores de NDVI. Por outro lado, ao final do ciclo, os valores tendem a reduzir, pois a cultura transloca suas reservas para os órgãos reprodutivos, como também ocorre a senescência de folhasedegradação da clorofila, evidenciando queda no NDVI

A (fig.17) expõe as imagens do índice NDRE proveniente das fontes de dados Planet Scope e Sentinel-2, onde para esse índice foram observadas variações mais acentuadas para o

Planet Scope apresentando um NDRE mínimo de 0.29 e um máximo de 0.39, enquanto o índice para o Sentinel-2 variou entre 0.05 e 0.13.

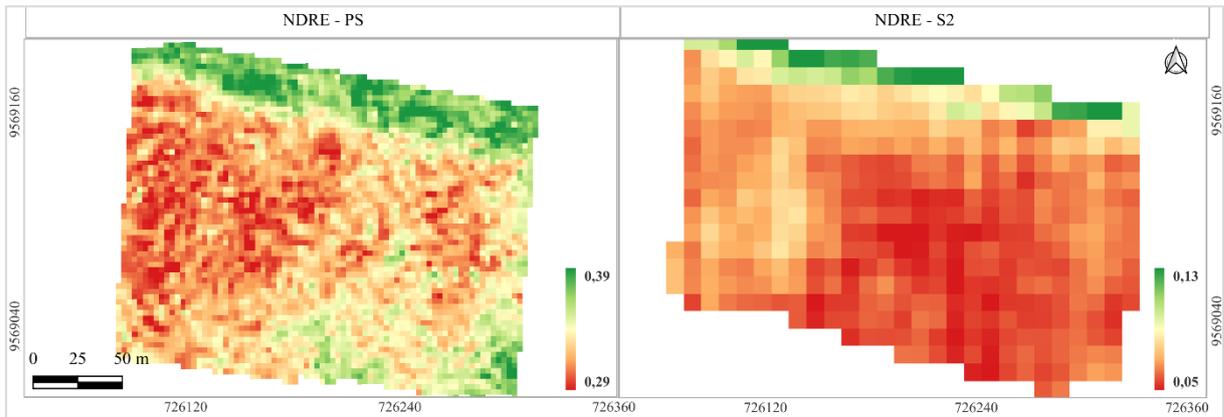


Figura 18: Imagens de NDRE dos dados orbitais aerotransportado.

Assim, de acordo com Sampaio (2021), o índice NDRE permite uma representação mais precisa da atividade fotossintética em estágios fenológicos mais avançados das plantas, ao contrário do NDVI, que se torna saturado nas fases finais do estágio vegetativo.

O índice VARI (Fig.18) apresentou variações nos valores mínimos e máximos, com o UAV registrando um VARI mínimo de 0.12 e um máximo de 0.33, o Planet Scope apresentando uma amplitude maior, variando de -0.1 a 0.17. O Sentinel-2, por sua vez, indicou áreas com menor atividade vegetativa, com valores do VARI variando de -0.08 a -0. O Landsat-8 registrou um VARI mínimo de 0,2 e um máximo de 0,07.

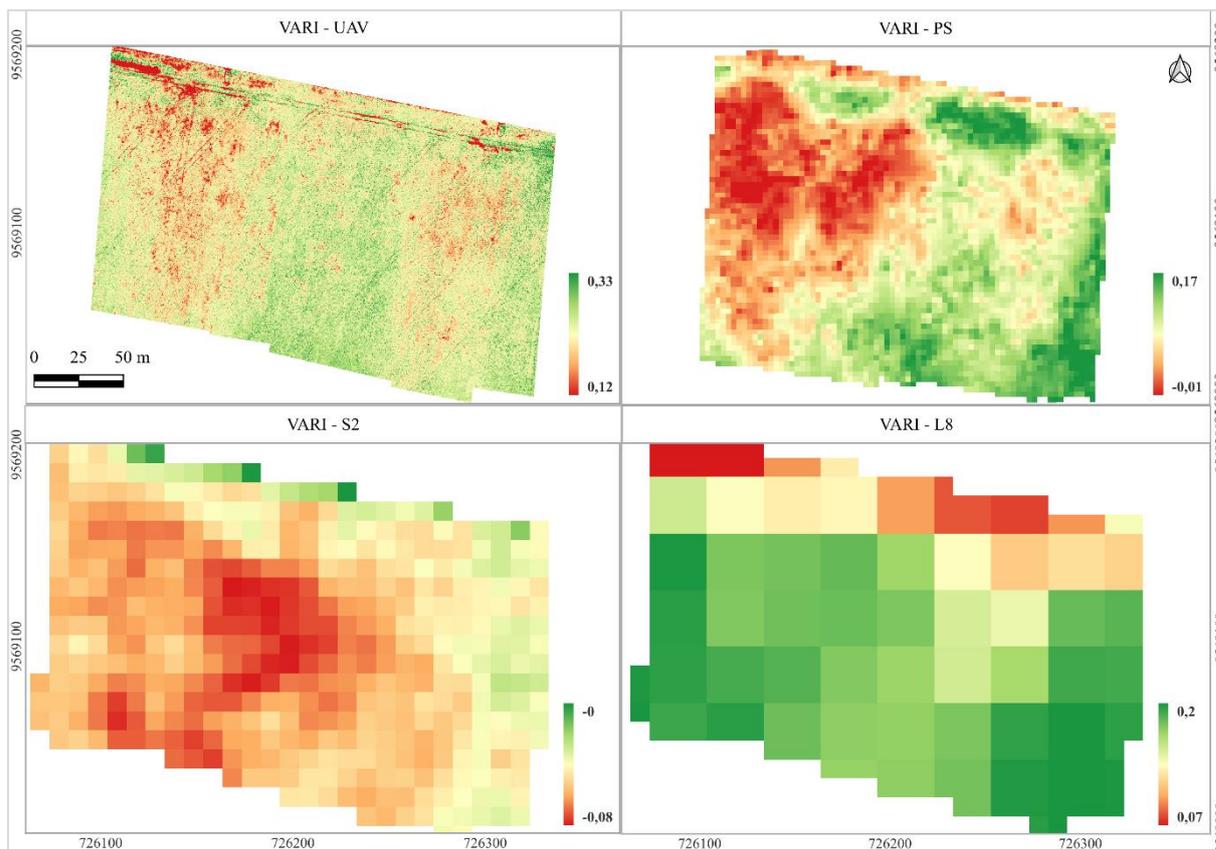


Figura 19: Imagens de VARI dos dados orbitais e aerotransportado.

Nos estudos de Trindade (2019) sobre a relação entre a evolução espectral-temporal dos índices de vegetação, atributos do solo e produtividade da soja, foram obtidos valores médios de -0,21, com um valor mínimo de -0,41 e um valor máximo de -0,02 para o índice VARI, considerando imagens coletadas 118 dias após a semeadura. Esses valores são parecidos aos encontrados no presente estudo, em que as imagens foram coletadas 122 dias após a semeadura. Os valores negativos do índice VARI nessa fase são justificados pelo fato de que a soja está passando pelo processo de maturação plena, uma vez que esse índice é sensível à fração vegetativa presente na imagem, conforme indicado por GITELSON et al., (2003).

Conforme mencionado por Thomas e Costa (2010), as diferenças nas características das imagens de cada índice de vegetação podem ser explicadas pelo estágio de desenvolvimento das plantas, especificamente no estágio R8, em que ocorre o processo de maturação. Nessa fase, o amarelecimento das vagens se destaca como um dos principais indicadores desse estágio. O estágio R8 é identificado pelo momento em que pelo menos uma vagem no caule atinge a coloração madura.

Borrmann (2009) destaca sobre a fase final do crescimento da soja, na qual ocorre um processo natural de envelhecimento, resultando na degradação da clorofila. Nesse momento, observa-se uma progressiva mudança de cor das vagens e sementes, passando do verde para o

amarelo, ao mesmo tempo em que as folhas começam a cair gradualmente.

O histograma da frequência de valores de pixel para o índice de vegetação GLI e NDVI (Fig. 20) revela padrões e características distintas em cada um deles.

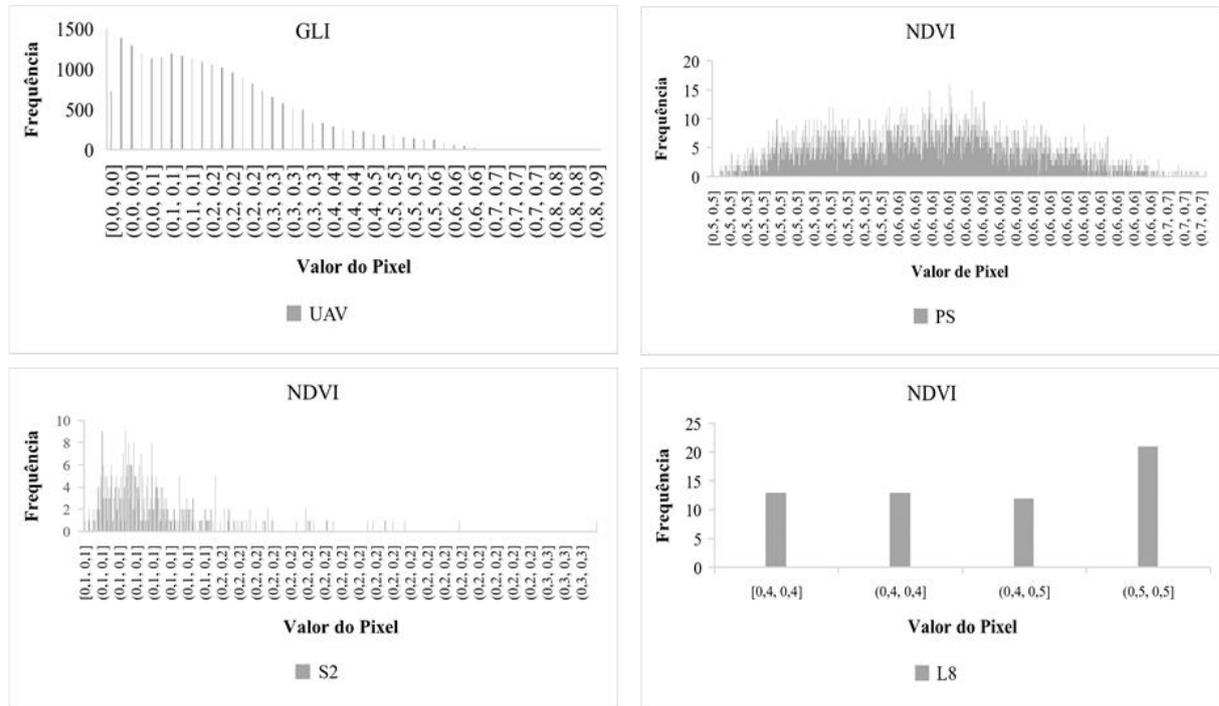


Figura 20: Histogramas GLI do UAV, NDVI do Planet Scope, Sentinel-2 e Landsat-8.

A frequência do valor de pixel do índice GLI obtido por meio de VANT, permite observar uma predominância de pixels com valores entre 0 e 0.5, sendo que a frequência mais alta se encontra na faixa de 0 a 0.2. Valores acima de 0.5 apresentam uma frequência menor. No caso do NDVI do Planet Scope, os valores de pixel se distribuem na faixa de 0 a 20, enquanto o NDVI do Sentinel-2 mostra uma concentração nos intervalos de 0 a 1, com picos em torno de 0.1 e 0.2. Já o NDVI do Landsat 8 apresenta uma distribuição predominantemente concentrada no valor de 0.4.

A análise do histograma da frequência de valores de pixel para o índice de vegetação NDRE (Fig. 21) revela padrões e características únicas desse índice para as diferentes fontes de dados.

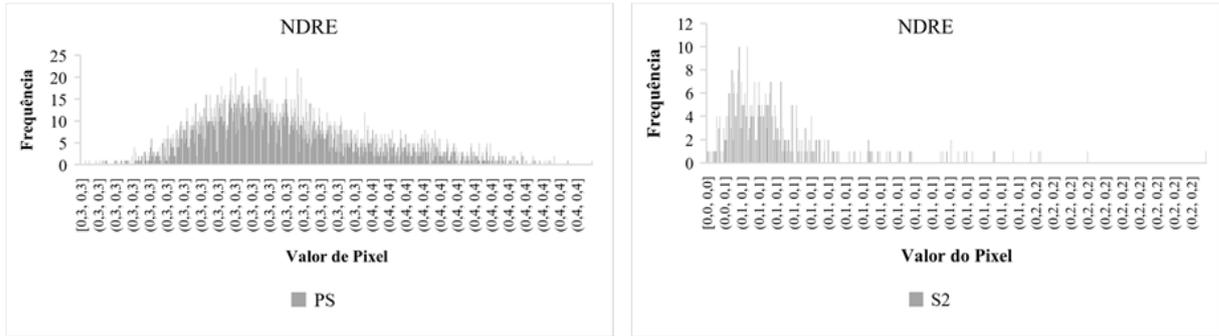


Figura 21: Histogramas NDRE do Planet Scope e Sentinel-2.

Na análise da frequência dos valores de pixel do índice NDRE, pode-se observar que ocorrem em intervalos distintos para diferentes fontes de imagens. No caso do satélite Planet Scope, os valores se concentram em uma faixa entre 0.3 e 0.4. Por outro lado, para o Sentinel-2, os valores estão mais concentrados na faixa de 0.1. Essas diferenças na distribuição dos valores de NDRE refletem a variação da vegetação e das características das áreas capturadas por cada fonte de imagens.

Ao examinar o histograma da frequência de valores de pixel para o índice de vegetação NDRE (Fig. 22), pode-se identificar diferentes padrões e características específicas desse índice em relação a cada fonte de dados.

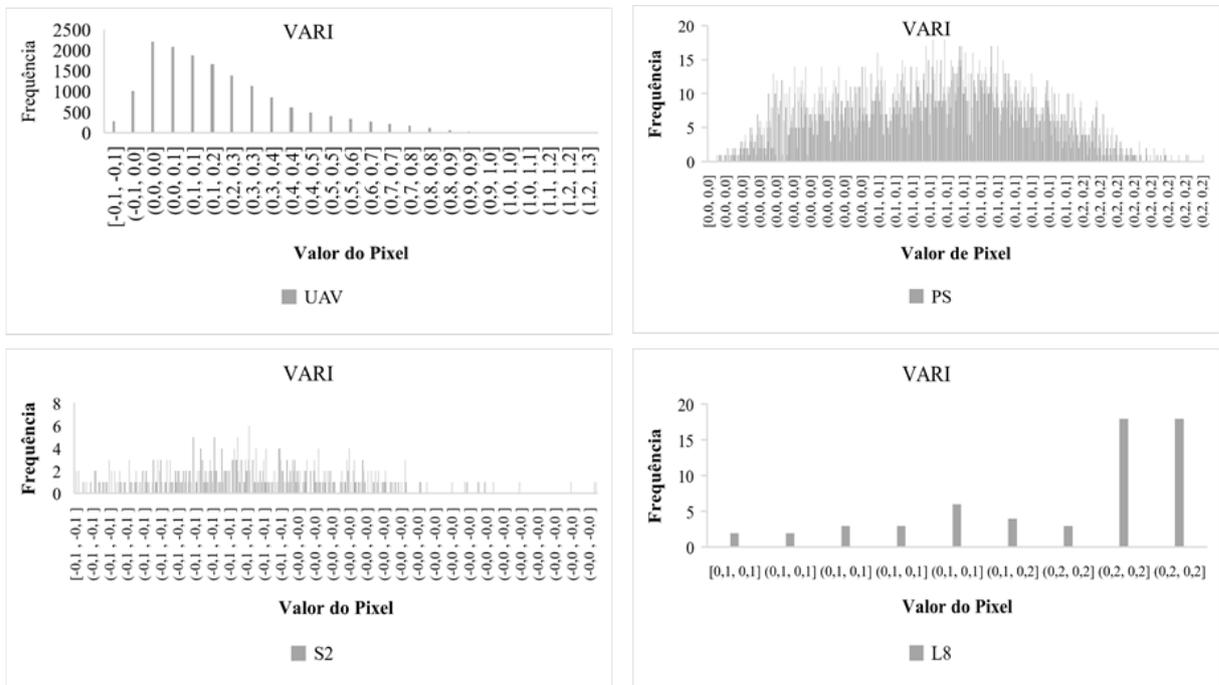


Figura 22: Histogramas de distribuição e frequência dos pixels referentes aos mapas de distribuição dos IVs.

O histograma do VARI, obtido por meio de imagens de UAV, apresenta uma

distribuição variada dos valores de pixel, com maior frequência próxima a -0.1 e uma diminuição gradual à medida que os valores aumentam. Por outro lado, o VARI proveniente do Planet Scope exibe uma variação uniforme no intervalo de 0.0 a 0.2. Quanto ao Sentinel-2, seu intervalo varia de -0.1 a 0.0, enquanto o Landsat apresenta valores no intervalo de 0.1 a 0.2.

Essa análise dos histogramas dos índices de vegetação está em linha com a abordagem proposta por Salles e Ling (1993), que destaca a importância do histograma na representação da distribuição dos valores de pixel em uma imagem. A abordagem de segmentação, baseada nos valores numéricos dos pixels presentes no histograma, visa dividir a imagem em partes consideradas homogêneas de acordo com critérios de uniformidade, o que facilita a segmentação da área de estudo na imagem do mapa.

6 CONCLUSÕES

- Através deste trabalho foi possível obter e gerar índices de vegetação (NDVI, VARI e NDRE) para as imagens dos sensores orbitais utilizando a plataforma Google Earth Engine;
- O NDVI mostrou maior amplitude e consistência de valores, enquanto o NDRE variou significativamente, e o VARI apresentou características distintas nas fontes de dados orbitais e aerotransportados;
- Os resultados destacam a importância de considerar as particularidades de cada fonte de dados no monitoramento e controle de áreas plantadas;
- As técnicas de sensoriamento remoto e agricultura digital foram consideradas viáveis e eficientes para o monitoramento da lavoura de soja.

Com isso recomenda-se investigar a relação entre os índices de vegetação obtidos pelos sensores orbitais e aerotransportados e dados coletados in situ, como amostragens de campo e medições diretas, para validar e aprimorar a confiabilidade dos resultados obtidos pelo sensoriamento remoto.

REFERÊNCIAS

- ABREU JÚNIOR, C. A. M. D. **Uso de imagens multiespectrais na estimativa de produtividade em áreas de culturas cafeeiras**. 2019. 71f. Trabalho de Conclusão de Curso. (Engenharia de Agrimensura e Cartográfica), Universidade Federal de Uberlândia, Monte Carmelo, 2019.
- ACHAPARINI, L.; FONTANA, D.; DALMAGO, G.; RODIGHERI, G.; FERNANDES, J., SANTI, A.; VARGAS, P. (2019). Análise comparativa entre índices de vegetação e sua relação com o balanço hídrico em soja. **Agrometeoros**, Passo Fundo, v.27, n.1, p.183-190, 2019.
- AIRE, N. P. **Relação dos índices de vegetação com a produtividade de milho em áreas irrigadas no Rio Grande do Sul**. 2022. 94f. Dissertação. (Mestrado em Agricultura de Precisão) - Universidade Federal de Santa Maria.2022.
- ANABITARTE, A.; SUBIZA-PÉREZ, M.; IBARLUZEA, J.; AZKONA, K.; GARCÍA-BAQUERO, G.; MIRALLES-GUASCH, C.; LERTXUNDI, A. Testing the multiple pathways of residential greenness to pregnancy outcomes model in a sample of pregnant women in the metropolitan area of Donostia-San Sebastian. **International journal of environmental research and public health**, v. 17, n. 12, p. 4520, 2020.
- ANDRADE JUNIOR, A. S. D.; MELO, F. D. B.; BASTOS, E. A.; CARDOSO, M. J. Evaluation of the nutritional status of corn by vegetation indices via aerial images. **Ciência Rural**, v. 51, 2021.
- ANDRADE, B. C. C. **Estimativa da evapotranspiração real via sensoriamento remoto**. 2018.135f. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos). Universidade Federal de Minas Gerais, Escola de Engenharia. 2018.
- ANDRADE, R.; HOTT, M.; de MAGALHAES JUNIOR, W. C. P.; OLIVEIRA, P. D.; OLIVEIRA, J. **Uso de veículo aéreo não tripulado (VANT) como plataforma para monitoramento da produção agropecuária: estudo de caso para o milho forrageiro**.2019. Disponível em: < <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1108242>> Acesso em: 15 nov. 2022
- APROSOJA - Associação Brasileira dos Produtores de Soja. **A Soja: Origem do grão**. Disponível em: < <https://aprosojabrasil.com.br/a-soja/>>. Acesso em: 14 out. 2022a.
- APROSOJA - Associação Brasileira dos Produtores de Soja. **Com potencial de expansão, "MaToPiBa" dribla a seca e prevê aumento na produção de soja**. Disponível em: <<https://www.aprosojams.org.br/com-potencial-de-expansao-matopiba-dribla-a-seca-e-preve-aumento-na-producao-de-soja>>. Acesso em: 13 out. 2022b.
- ARAUJO, H. B.; PEREIRA, P. R. M.; RODRIGUES, T. C. S.; COSTA JUNIOR, E. P. B. Mudança de cobertura da terra nos municípios de Chapadinha e Buriti - MA, entre os anos de 1990 a 2017. 2019. **Revista Geonorte**, v. 10, n. 36, p. 194-214, 2019.

ASBRAAP - Associação Brasileira de Agricultura de Precisão e Digital. **Definições de Agricultura de Precisão**. Disponível em: <<https://asbraap.org/index.php?page=ap>>. Acesso em: 29 out. 2022.

BASSOI, L. H.; INAMASU, R. Y.; BERNARDI, A. C. C.; VAZ, C. M. P.; SPERANZA, E. A.; CRUVINEL, P. E. Agricultura de precisão e agricultura digital. **Revista Digital de Tecnologias Cognitivas**, São Paulo, v. 3, n. 20, p.17-36, 2019.

BOLFE, E. L.; MASSRUHÁ, S. M. F. S. A transformação digital e a sustentabilidade agrícola. **AgroANALYSIS**, v. 40, n. 3, p. 32-34, 2020.

BORRMANN, D. **Efeito do déficit hídrico em características químicas e bioquímicas da soja e na degradação da clorofila, com ênfase na formação de metabolitos incolores**. 2009. 125f. Tese de Doutorado. (Programa de Pós-graduação em Ciências dos Alimentos) - Universidade de São Paulo. 2009.

CARON, M. L.; MINUZZI, R. B. Estimativa de produtividade de soja com uso de perfis temporais de índices de vegetação do sensor MODIS no município de Sapezal, Mato Grosso. **Revista Brasileira de Geografia Física**, v. 15, n. 2, p. 1153-1168, 2022.

CASELLA, A.; BARRIONUEVO, N., PEZZOLA, A.; WINSCHER, C. Pré-processamento de imagens de satélite do sensor sentinel 2A e 2B com o software SNAP 6.0 **Instituto de Clima y Agua. CIRN INTA Castelar. Buenos Aires, Argentina**, p. 1-31, 2018.

CASTILLO, R.; BOTELHO, C. A.; DEZIDÉRIO, M. Agronegócio globalizado no MATOPIBA maranhense: análise da especialização regional produtiva da soja. **Revista brasileira de geografia econômica**, Viçosa, v. 6, n. 1, p. 64-73, 2016. Disponível em: <<https://doi.org/10.4000/espacoeconomia.19325> >. Acesso em: 28 de out. de 2022.

CAVALCANTE, L. A. S. **Delineamento de zonas de manejo por imagens suborbitais, orbitais e variáveis de solo**. 2020.117 f. Dissertação (Programa de Pós-Graduação em Engenharia Agrícola). Universidade Estadual do Oeste do Paraná, 2020.

CHAMARA, N.; ISLAM, M. D.; BAI, G. F.; SHI, Y.; GE, Y. Ag-IoT for crop and environment monitoring: Past, present, and future. **Agricultural Systems**, v. 203, p. 103497, 2022.

CONAB - Companhia Nacional de Abastecimento. **A produtividade da soja: análise e perspectivas**, 2018. Disponível em: <<https://www.conab.gov.br/busca?searchword=Comp%C3%AAndio%20de%20estudos&searchphrase=all>>. Acesso em: 14 out. 2022.

CONAB – Companhia Nacional de Abastecimento. **Boletim Safras de Grãos, 10º Levantamento - Safra 2022/23**. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>. Acesso em: 13 jul. 2023.

COSTA, E. D. C. **Epidemiologia comparativa de mancha alva da soja no Cerrado brasileiro**. 2020. 74f. Dissertação. (Programa de Pós-graduação em Fitopatologia) - Universidade de Brasília, Brasília, 2020

DIOGO, A. M.; MATEUS, N. P. A. **Vegetação de Angola: Caracterização Fenológica da Vegetação**. Editora Dialética. 2022. 90f. Disertação (Programa de Pós-Graduação em Sensoriamento- PPGSR). Universidade Federal do Rio Grande do Sul. Porto Alegre, 2020.

DJI - **Especificações Phantom 4 Pro V2.0**. Disponível em: < <https://www.dji.com/br/phantom-4-pro-v2/specs>>. Acesso em: 28 jun. 2023.

EITEL, J. U.; VIERLING, L. A.; LITVAK, M. E.; LONG, D. S.; SCHULTHESS, U.; AGER, A. A.; STOSCHECK, L. Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. **Remote Sensing of Environment**, v. 115, n. 12, p. 3640-3646, 2011.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Soja brasileira tem tecnologia para aumento de produção sem pressão por áreas de florestas**, 2021. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/58680839/soja-brasileira-tem-tecnologia-para-aumento-de-producao-sem-pressao-por-areas-de-florestas>>. Acesso em: 15 out. 2022.

ENG, L. S.; ISMAIL, R.; HASHIM, W.; BAHARUM, A. The use of VARI, GLI, and VI-green formulas in detecting vegetation in aerial images. **International Journal of Technology**, v. 10, n. 7, p. 1385-1394, 2019.

FREITAS, L. M. B; GIONGO, P. R. XV. Índices de vegetação e dados satelitários aplicados na avaliação da degradação de pastagens. In: SHINOHARA, N. K. S.; OLIVEIRA, F. H. Q. P. C.; FONTGALLAND, I. L.; BRITO, H. C. **Meio ambiente e sociedade: análises, diálogos e conflitos ambientais**. 3º ed. Campina Grande: Editora Amplla, 2022. p. 224-231.

FUNDAJ - Fundação Joaquim Nabuco. **Panorama Setorial - Força do Matopiba**. Disponível em: < <https://www.gov.br/fundaj/pt-br/destaques/observa-fundaj-itens/observa-fundaj/tecnologias-de-convivencias-com-as-secas/panorama-setorial-forca-do-matopiba>>. Acesso em: 13 out. 2022.

GIOVANINI, A. **Sensoriamento remoto aplicações - Funcionamento dos sistemas sensores**. Disponível em: <<https://adenilsongiovanini.com.br/blog/sensoriamento-remoto-aplicacoes/>> Acesso em: 01 nov. 2022.

GITELSON, A. A.; STARK, R.; GRITS, U., RUNDQUIST, D.; KAUFMAN, Y.; DERRY, D. Vegetation and soil lines in visible spectral space: A concept and technique for remote estimation of vegetation fraction. **International Journal of Remote Sensing**, v. 23, n. 13, p. 2537-2562, 2002.

GREGORIO, H. J., JATENCO, P. V.; OLIVEIRA, C. M. **Fundamentos de astronomia**. São Paulo: IAG-USP, 2000.

HOTT, M. C.; ANDRADE, R. G.; MAGALHÃES JUNIOR, W. C. P.; BENITES, F. R. G. Uso de veículo aéreo não tripulado (VANT) para estimativa de vigor e de correlações agronômicas em genótipos de capim Cynodon. **SILVA, HC Engenharia Sanitária e Ambiental. Ponta Grossa: ATENA Editora**, p. 235-244, 2019.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal 2007, 2008**. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/buriti/pesquisa/31/29644?tipo=ranking&indicador=29724/>>. Acesso em: 28 de out. de 2022.

IBGE - Instituto Brasileiro de Geografia e. **Cidades e Estados**. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/ma/buriti.html>>. Acesso em: 15 jun. 2023.

JARDIM, R. O. MUDANÇA NA COBERTURA VEGETAL DO MUNICÍPIO DE BREJO (MA): uma análise a partir do cálculo do Índice de Vegetação por Diferença Normalizada (NDVI). **Ensaios de Geografia**, v. 7, n. 14, p. 147-162, 2022.

KAKAMOUKAS, G. A.; SARIGIANNIDIS, P. G.; ECONOMIDES, A. A. FANETs in Agriculture-A routing protocol survey. **Internet of Things**, v. 18, p. 100183, 2022.

KLERING, E. V.; FONTANA, D. C.; ROGLIO, V. S.; ALVES, R. D. C. M.; BERLATO, M. A. Modelo agrometeorológico-espectral para estimativa da produtividade de grãos de arroz irrigado no Rio Grande do Sul. **Bragantia**, v. 75, p. 247-256, 2016.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. 2. ed. Campo Grande, MS: UNIDERP Editora, 2006. 908p. Disponível em:<http://ofitexto.arquivos.s3.amazonaws.com/Aplica%C3%A7%C3%B5es%20de%20Sensoriamento%20Remoto%20ed_DEG.pdf> Acesso em: 30 out. 2022.

MAIA, F. C. O. **Utilização de índices de vegetação para identificação de ambientes de produção de cana-de-açúcar**. 2019. 86f. Dissertação (Mestrado em Agronomia). Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília. 2019.

MAIMAITIJIANG, M.; SAGAN, V.; SIDIKE, P.; HARTLING, S.; ESPOSITO, F.; FRITSCHI, F. B. Soybean yield prediction from UAV using multimodal data fusion and deep learning. **Remote sensing of environment**, v. 237, p. 20, 2020. Disponível em:< <https://www.sciencedirect.com/science/article/abs/pii/S0034425719306194>> Acesso em: 05 nov. 2022.

MARCHIORO, V. **Aprendizagem de máquina na definição de zonas homogêneas de manejo para soja**. 2023. 91f. Tese (Doutorado em Agronomia). Faculdade de Ciências Agrárias e Veterinárias - FCAV/Unesp, Campus de Jaboticabal. 2023.

MASSRUHÁ, S. M. F. S.; LEITE, M. D. A.; LUCHIARI JUNIOR, A.; Evangelista, S. R. M. **A transformação digital no campo rumo à agricultura sustentável e inteligente**. Embrapa Agricultura Digital-Livro científico (ALICE), 2020. 406 p. Disponível em:< <https://www.alice.cnptia.embrapa.br/handle/doc/1126213>>. Acesso em: 28 de out. de 2022.

MOLIN, J. P.; BAZAME, H. C.; MALDANER, L.; CORREDO, L. D. P.; MARTELLO, M. Agricultura de precisão e as contribuições digitais para a gestão localizada das lavouras. **Revista Ciencia Agronomica**, v. 51, 2021., v. 51, 2021.

MOLIN, J. P.; DO AMARAL, L. R.; COLAÇO, A. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de Textos, 2015. 224 p. Disponível em:< <https://www.bibliotecaagritea.org.br/agricultura/precisao/livros/AGRICULTURA%20DE%20PRECISAO%20-%20OFICINA%20DE%20TEXTOS.pdf>> Acesso em: 29 out. 2022.

MUÑOZ, A. N. M.; BRUNN, A; CHAPARRO, J.; PÉREZ, A. Programação Paralela para Analisar a Saúde das Culturas em Tempo Real. **ZfV-Zeitschrift für Geodäsie, Geoinformation und Land Management**. Wurzburg, Alemanha, v. 4. p. 59-205, 2019.

NAGUIB, N. S.; DALIMAN, S. Analysis of NDVI and NDRE Indices Using Satellite Images for Crop Identification at Kelantan. In: **IOP Conference Series: Earth and Environmental Science**. IOP Publishing, 2022. p. 012054.

NONATO, C. T.; ABREU, Y. V. **Desenvolvimento de modelos de classificação de florestas plantadas para planejamento e tomada de decisão: Mineração de Dados e Imagens de Satélite**. 1. ed. Campo Grande, MS: Life Editora, 2020.124p. Disponível em:< https://books.google.com.br/books?id=yMkLEAAAQBAJ&sitesec=buy&hl=pt-BR&source=gbs_atb> Acesso em: 29 out. 2022.

OZTURK, M. Y.; ÇOLKESEN, İ. The impacts of vegetation indices from UAV-based RGB imagery on land cover classification using ensemble learning. **Mersin Photogrammetry Journal**, v. 3, n. 2, p. 41-47, 2021.

PARANHOS FILHO, A. C.; MIOTO, C. L.; PESSI, D. D.; GAMARRA, R. M.; SILVA, N. M.; RIBEIRO, V. O; CHAVES; J. R. **Geotecnologias para aplicações ambientais**. 1. Ed. Maringá-PR: Uniedusul, 2021. 394p. Disponível em:<https://www.researchgate.net/publication/348311012_Geotecnologias_para_Aplicacoes_Ambientais> Acesso em: 06 nov. 2022.

PEREIRA, L. F.; GUIMARÃES, R. M. F.; OLIVEIRA, R. R. M. Integrando geotecnologias simples e gratuitas para avaliar usos/coberturas da terra: QGIS e Google Earth Pro. **Journal of Environmental Analysis and Progress**, Pernambuco, v. 03 n. 03, p. 250-264, 2018. Disponível em:<doi.org/10.24221/jeap.3.3.2018.1839.250-264> Acesso em: 07 nov. 2022.

QUEIROZ, D. M.; VALENTE, D. S.M.; DE CARVALHO PINTO, F. D. A.; BORÉM, A. **Agricultura digital**. 2. ed. São Paulo: Oficina de Textos, 2021. 224 p. Disponível em:<https://s3-sa-east-1.amazonaws.com/ofitexto.arquivos/degustacao/agricultura-digital-2ed_deg.pdf> Acesso em: 29 out. 2022.

RAVANELLI, R.; NASCETTI, A.; CIRIGLIANO, R. V.; DI RICO, C.; LEUZZI, G.; MONTI, P.; CRESPI, M. Monitoring the impact of land cover change on surface urban heat island through Google Earth Engine: Proposal of a global methodology, first applications and problems. **Remote Sensing**, v. 10, n. 09, p. 1488, 2018.

RODRIGUES, T. W. P.; GUIMARÃES, U. S.; ROTTA, L. H. D. S.; WATANABE, F. S. Y.; ALCÂNTARA, E.; IMAI, N. N. Delineamento amostral em reservatórios utilizando imagens Landsat-8/OLI: um estudo de caso no reservatório de Nova Avanhandava (Estado de São Paulo, Brasil). **Boletim de Ciências Geodésicas**, v. 22, p. 303-323, 2016.

SALLES, E. O. T.; LING, L. L. Uma aplicação de sistemas nebulosos em processamento de imagens. In **Anais do Congresso Brasileiro de Automação**. 1993. Departamento de Engenharia Elétrica Universidade Federal do Espírito Santo-UFES, 1993.

SAMPAIO, M. I. R.; KUNZ, A.; HILLEBRAND, F. L.; ZAMBERLAN, J. F.; IDALINO, F. D. Análise dos índices de vegetação NDVI e NDRE em imagens obtidas por meio de sensor embarcado em um RPAS para as culturas da soja (*Glycine max*) e milho (*Zea mays*) irrigados. **Revista Brasileira de Geomática**, v. 9, n. 4, p. 350-362, 2021.

SANNIER, C.; HERRMANN, D.; MOSER, L.; SCHWAB, K.; LINDMAYER, A.; PROBECK, M.; SEVILLANO, E.; VILLEROT, S. **ECoLaSS: Evolution of Copernicus Land Services based on Sentinel data**. Disponível em:< https://www.researchgate.net/publication/358881008_D42_-D221b_-EO_and_other_data_requirements_Report_Issue_2_Issue_2_Horizon_2020_ECoLaSS> Acesso em: 06 nov. 2022.

SANTOS, G. G.; SOUSA, S. J.; SANTOS, G. M.; NERES, F. P. J.; FREITAS, M. P. T. Análise espaço-temporal da produção de soja na microrregião de chapadinha - MA. In: V Congresso Internacional das Ciências Agrárias. **Anais Recife**, 2020. Disponível em: <<https://cointer.institutoidv.org/smart/2020/pdvagro/uploads/1982.pdf>>. Acesso em: 13 out. 2022.

SANTOS, L. M. G.; PENATTI, N. C.; DELALIBERA, H. C.; GUIMARÃES, M. F. Relação entre os mapas dos índices vegetativos NDRE, NDVI, e EVI com um mapa de zonas de potencial produtivo para soja. In: LI Congresso Brasileiro de Engenharia Agrícola-CONBEA, 10, 2022. **Anais**. Pelotas Parque Tecnológico – Pelotas – RS.

SEARCHINGER, T.; HANSON, C.; RANGANATHAN, J.; LIPINSKI, B.; WAITE, R.; WINTERBOTTOM, R.; ARI, T. B. **Creating a sustainable food future. A menu of solutions to sustainably feed more than 9 billion people by 2050**. World resources report 2013-14: interim findings. 2014.154 p. Disponível em: <<https://hal.archives-ouvertes.fr/hal-01129910/>>. Acesso em: 29 de out. de 2022.

SECCON (Tecnologia Geoespacial e Mapeamento via Satélite). **Imagens PlanetScope com 8 Bandas**. 2022. Disponível em: <<https://www.scon.com.br/imagens-planetoscope-com-8-bandas-plataforma-scon/>>. Acesso em: 01 jul. 2023

SHIRATSUCHI, L. S.; BRANDÃO, Z. N.; VICENTE, L. E.; VICTORIA, D. D. C., DUCATI, J. R., OLIVEIRA, R. P.; VILELA, M. D. F. **Agricultura de Precisão - resultados de um novo olhar**: Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. 1 ed. Brasília, DF: Embrapa, 2014. p 58-73.

SILVA, H. F. **Mapeamento de zonas potenciais á ocorrência de águas subterrâneas na porção nordeste do município de caçapava do sul: uma integração de SIG, sensoria-mento remoto e análise multicritério**. 2019. 74f. Trabalho de Conclusão de Curso (Graduação em Geologia), Universidade Federal do Pampa, Caçapava do Sul, 2019.

SILVA, J. M. P.; CAVICHIOLI, F. A. O Uso da Agricultura 4.0 como Perspectiva do Aumento da Produtividade no Campo. **Revista Interface Tecnológica**, [S. l.], v. 17, n. 2, p. 616–629, 2020. DOI: 10.31510/infa.v17i2.1068. Disponível em: <https://revista.factectq.edu.br/interfacetecnologica/article/view/1068>. Acesso em: 29 out. 2022.

SILVA, L. C. D. A. **Delineamento de zonas de manejo por imagens suborbitais, orbitais e variáveis de solo**. 2020. 117f. Dissertação (Programa de Pós-Graduação em Engenharia Agrícola). Universidade Estadual do Oeste do Paraná Campus de Cascavel. Paraná. 2020.

SOUZA, J. B. C.; DE BRITO FILHO, A. L., CARNEIRO, F. M.; DO SANTOS, A. F.; DA SILVA, R. P. Avaliação da qualidade dos índices de vegetação (NDRE e NDVI) para a cultura do amendoim, utilizando cartas de controle. **South American Sciences**, v. 1, n. 1, p. e2095-e2095, 2020.

SOUZA, S. de M. de.; PARANHOS FILHO, A. C. Índices de vegetação aplicados a identificação de tipos de cultura. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, São Paulo, 2021.

TRINDADE, F. S.; DE CARVALHO ALVES, M.; NOETZOLD, R., DE ANDRADE, I. C.; POZZA, A. A. A. Relação espectro-temporal de índices de vegetação com atributos do solo e produtividade da soja. **Revista de Ciências Agrárias Amazonian Journal of Agricultural and Environmental Sciences**, v. 62, 2019.

TUCKER, C. J.; GARRATT, M. W. Leaf optical system modeled as a stochastic process. **Applied optics**, v. 16, n. 3, p. 635-642, 1977.

VELUSAMY, P.; RAJENDRAN, S.; MAHENDRAN, R. K.; NASEER, S.; SHAFIQ, M.; CHOI, J. G. Unmanned Aerial Vehicles (UAV) in precision agriculture: applications and challenges. **Energies**, v. 15, n. 1, p. 217, 2021.

VIEIRA PASSOS, M. L.; BAGANHA RAPOSO, A.; JOSÉ MENDES, T. Estimativa da Distribuição da Precipitação Pluviométrica Provável em Diferentes Níveis de Probabilidade de Ocorrência. **Revista Brasileira de Agricultura Irrigada-RBAI**, v. 11, n. 1, 2017.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. Oficina de Textos. 2. ed. São Paulo: Oficina de Textos, 2019. 320p. Disponível em: <https://s3-sa-east-1.amazonaws.com/ofitexto/arquivos/degustacao/processamento-de-imagens-de-satelite_deg.pdf> Acesso em: 29 out. 2022.

ZAPAROLLI, D. **Inovação no campo**. Disponível em: <<https://revistapesquisa.fapesp.br/inovacao-no-campo/>>. Acesso em: 29 de out. de 2022.

ZHANG, H.; WANG, L.; TIAN, T.; YIN, J. A review of unmanned aerial vehicle low-altitude remote sensing (UAV-LARS) use in agricultural monitoring in China. **Remote Sensing**, v. 13, n. 6, p. 1221, 2021.

ZHANG, T.; SU, J.; LIU, C.; CHEN, W. H.; LIU, H.; LIU, G. Band selection in Sentinel-2 satellite for agriculture applications. In: **2017 23rd international conference on automation and computing (ICAC)**. IEEE. p. 1-6. 2017.

ZHAO, Q.; YU, L.; LI, X., PENG, D.; ZHANG, Y.; GONG, P. Progress and trends in the application of Google Earth and Google Earth Engine. 2021. **Remote Sensing**, v. 13, n. 18, p. 3778, 2021.